



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



DENIS PEREIRA DOS SANTOS

**PREVISÃO HISTÓRICA DAS SAFRAS DE CULTURAS DE CICLO CURTO DO
ESTADO DE ALAGOAS COM MODELOS DO CMIP6**

MACEIÓ – AL
FEVEREIRO - 2025

DENIS PEREIRA DOS SANTOS

**PREVISÃO HISTÓRICA DAS SAFRAS DE CULTURAS DE CICLO CURTO DO
ESTADO DE ALAGOAS COM MODELOS DO CMIP6**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Meteorologia da Universidade Federal de Alagoas, como parte dos requisitos para o grau de mestre em meteorologia.

Orientador: Prof. Dr. Fabricio Daniel dos S. Silva
Coorientadora: Profa. Dra. Rafaela Lisboa Costa

MACEIÓ – AL

2025

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico

Bibliotecária: Girlaine da Silva Santos – CRB-4 – 1127

S237p Santos, Denis Pereira dos.

Previsão histórica das safras de culturas de ciclo curto do Estado de Alagoas com modelos do cmip6 / Denis Pereira dos Santos. – 2025.
48 f. : il.

Orientador: Fabricio Daniel dos S. Silva.

Coorientadora: Rafaela Lisboa Costa.

Dissertação (Mestrado em Meteorologia.) – Universidade Federal de Alagoas, Instituto de Ciências Atmosféricas. Programa de Pós-Graduação em Meteorologia. Maceió, 2025.

Bibliografia: f. 42 - 48.

1. Mudanças climáticas. 2. Climatologia agrícola (AL). 3. Produtividade Agrícola. 4. Precipitação(Meteorologia) - Variabilidade. 5. Correlação canônica (Estatística). I. Título.

CDU: 551.583: 631(813.5)



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

CERTIFICADO DE APRESENTAÇÃO

N.º de ordem: MET-UFAL-MS-211.

“PREVISÃO HISTÓRICA DAS SAFRAS DE CULTURAS DE CICLO CURTO DO ESTADO DE ALAGOAS COM MODELOS DO CMIP6.”

DÊNIS PEREIRA DOS SANTOS

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:

Documento assinado digitalmente
gov.br FABRÍCIO DANIEL DOS SANTOS SILVA
Data: 24/02/2025 18:14:07-0300
Verifique em <https://validar.iti.gov.br>

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

Documento assinado digitalmente
gov.br RAFAELA LISBOA COSTA
Data: 24/02/2025 18:25:02-0300
Verifique em <https://validar.iti.gov.br>

Prof.^a Dr.^a Rafaela Lisboa Costa
(Coorientadora)

Documento assinado digitalmente
gov.br HELIOFABIO BARROS GOMES
Data: 24/02/2025 20:42:33-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Heliofábio Barros Gomes
(Membro Interno)

Documento assinado digitalmente
gov.br HELDER JOSE FARIAS DA SILVA
Data: 24/02/2025 20:19:31-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Helder José Farias da Silva
(Membro Externo)

Documento assinado digitalmente
gov.br KLEYTHON DE ARAUJO MONTEIRO
Data: 27/02/2025 23:00:10-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Kleython de Araújo Monteiro
(Membro Externo)

FEVEREIRO/2025

AGRADECIMENTOS

Primeiramente, agradeço a Deus por ser meu guia.

À minha mãe, Ivone, *in memoriam*, sou eternamente grato. Sua presença estará sempre viva em mim. Você foi um exemplo de perseverança diante das dificuldades. E sim, este trabalho também é para ti.

Ao meu pai, aos meus irmãos e demais familiares, pelo apoio incondicional.

Ao meu orientador, Prof. Dr. Fabrício Daniel dos Santos Silva, e minha coorientadora, Profa. Dra. Rafaela Lisboa Costa, por serem pessoas incríveis. O meu eterno agradecimento a vocês.

Aos meus amigos e colegas, que sempre estiveram ao meu lado.

À Fundação de Amparo à Pesquisa do Estado de Alagoas (FAPEAL), pela concessão de bolsa de Mestrado.

RESUMO

A variabilidade da precipitação é um dos mais importantes fatores de sucesso ou fracasso de safras agrícolas cultivadas sob regime de sequeiro. Nessa pesquisa, buscou-se compreender a relação entre a precipitação acumulada no semestre mais chuvoso e a previsibilidade das safras de feijão, milho e mandioca nas três mesorregiões do estado de Alagoas. Devido a pequena extensão territorial do estado quando comparado a outros estados brasileiros, e baseado em literatura científica, constatou-se que a principal estação de crescimento dessas culturas se dá entre os meses de abril e setembro nas três mesorregiões: sertão, agreste e leste. Foram usados os dados de produção fornecidos pelo IBGE de cada cultura entre 1974 a 2014 para calibrar um sistema de previsão baseado na relação entre preditor: precipitação acumulada no semestre AMJJAS, e preditando: produção agrícola, utilizando para esse fim o método estatístico multivariado conhecido como análise de correlações canônicas (ACC). Essa técnica foi usada de duas formas, na primeira como um método simples para previsão de natureza puramente estatística, e na segunda como um método de correção de viés para calibração da precipitação estimada por oito modelos do CMIP6 para o Nordeste brasileiro (NEB). Assim como os dados de precipitação observada no NEB, precipitação obtida dos modelos ACCESS-CM2 (Austrália), BCC-CSM2-MR (China), CNRM-CM6-1-HR (França), GFDL-ESM4 (Estados Unidos), MIROC6 (Japão), NORESM2-MM (Noruega), INM-CM5-0 (Rússia) e TaiESM1 (Taiwan) no semestre AMJJAS foi usada com e sem correção de viés para prever a produção das culturas. A precipitação dos modelos mostra-se com fortes vieses em relação à observada, mas foram coerentemente corrigidas com ACC, diminuindo consideravelmente o viés, os erros e aumentando a correlação em relação à observada. No entanto, as simulações das culturas foram apenas levemente mais eficientes usando-se a precipitação corrigida dos modelos. Por fim, aplicando-se o conceito de ensemble, a melhor simulação da produção das culturas foi a proveniente da média das simulações obtidas a partir da precipitação original dos modelos, sem correção de viés com ACC, o que se tornou o resultado mais importante dessa pesquisa.

Palavras-chave: precipitação, análise de correlações canônicas, CMIP6, produtividade agrícola.

ABSTRACT

Rainfall variability is one of the most important factors in the success or failure of agricultural crops grown under rainfed conditions. This study sought to understand the relationship between accumulated rainfall in the wettest semester and the predictability of bean, corn and cassava harvests in the three mesoregions of the state of Alagoas. Due to the small territorial extension of the state when compared to other Brazilian states, and based on scientific literature, it was found that the main growing season for these crops is between the months of April and September in the three mesoregions: sertão, agreste and leste. Production data provided by the IBGE for each crop between 1974 and 2014 was used to calibrate a forecasting system based on the relationship between predictor: accumulated rainfall in the AMJJAS semester, and predictor: agricultural production, using the multivariate statistical method known as canonical correlation analysis (CCA). This technique was used in two ways, firstly as a simple method for purely statistical forecasting, and secondly as a bias correction method for calibrating the rainfall estimated by eight CMIP6 models for the Brazilian Northeast (NEB). As well as the observed rainfall data in the NEB, rainfall obtained from the ACCESS-CM2 (Australia), BCC-CSM2-MR (China), CNRM-CM6-1-HR (France), GFDL-ESM4 (United States), MIROC6 (Japan), NORESM2-MM (Norway), INM-CM5-0 (Russia) and TaiESM1 (Taiwan) models in the AMJJAS semester was used with and without bias correction to predict crop production. The rainfall from the models shows strong biases in relation to the observed rainfall, but they were consistently corrected with ACC, considerably reducing the bias, the errors and increasing the correlation in relation to the observed rainfall. However, crop simulations were only slightly more efficient using the corrected rainfall from the models. Finally, by applying the ensemble concept, the best simulation of crop production came from the average of the simulations obtained from the models' original rainfall, without bias correction with ACC, which became the most important result of this research.

Keywords: rainfall, canonical correlation analysis, CMIP6, agricultural yield.

LISTA DE FIGURAS

Figura 1. Fases do desenvolvimento do feijoeiro. Fonte: EMBRAPA.	10
Figura 2. Terceira safra de feijão. Fonte: CONAB.	11
Figura 3. Safra do Milho. Fonte: CONAB.	12
Figura 4. (a) NEB e (b) Alagoas, com suas três mesorregiões com os respectivos municípios, cujos centroides (pontos azuis), serviram de referência para a construção do banco de dados de precipitação extraída de Xavier et al. (2022).....	13
Figura 5. Esquema ilustrativo das etapas utilizadas para as simulações da produtividade das culturas nas mesorregiões do NEB a partir da precipitação acumulada semestral e anual. No esquema, usa-se o milho para exemplificação (Autor, 2011).....	20
Figura 6. Climatologia da precipitação acumulada no verão (DJF), observada (a) e obtida dos modelos ACCESS-CM2 (b), BCC-CSM2-MR (c), CNRM-CM6-1-HR (d), GFDL-ESM4 (e), INM-CM5 (f), MIROC6 (g), NorESM2-MM (h) e TaiESM1 (i).	23
Figura 7. Climatologia da precipitação acumulada no outono (MAM), interpolada (a) e obtida dos modelos ACCESS-CM2 (b), BCC-CSM2-MR (c), CNRM-CM6-1-HR (d), GFDL-ESM4 (e), INM-CM5 (f), MIROC6 (g), NorESM2-MM (h) e TaiESM1 (i).	23
Figura 8. Climatologia da precipitação acumulada no inverno (JJA), interpolada (a) e obtida dos modelos ACCESS-CM2 (b), BCC-CSM2-MR (c), CNRM-CM6-1-HR (d), GFDL-ESM4 (e), INM-CM5 (f), MIROC6 (g), NorESM2-MM (h) e TaiESM1 (i).	24
Figura 9. Climatologia da precipitação acumulada na primavera (SON), interpolada (a) e obtida dos modelos ACCESS-CM2 (b), BCC-CSM2-MR (c), CNRM-CM6-1-HR (d), GFDL-ESM4 (e), INM-CM5 (f), MIROC6 (g), NorESM2-MM (h) e TaiESM1 (i).....	24
Figura 10. Viés global da precipitação média mensal dos MCGs em relação à observação para (a) ACCESS-CM2, (b) BCC-CSM2-MR, (c) CNRM-CM6-1-HR, (d) GFDL-ESM4, (e) INM-CM5, (f) MIROC6, (g) NorESM2-MM e (h) TaiESM1.	26
Figura 11. MAE da precipitação média mensal dos MCGs em relação à interpolação para (a) ACCESS-CM2, (b) BCC-CSM2-MR, (c) CNRM-CM6-1-HR, (d) GFDL-ESM4, (e) INM-CM5, (f) MIROC6, (g) NorESM2-MM e (h) TaiESM1..	26
Figura 12. RMSE da precipitação média mensal dos MCGs em relação à interpolação para (a) ACCESS-CM2, (b) BCC-CSM2-MR, (c) CNRM-CM6-1-HR, (d) GFDL-ESM4, (e) INM-CM5, (f) MIROC6, (g) NorESM2-MM e (h) TaiESM1.	27

Figura 13. Correlação (r) da precipitação média mensal dos MCGs em relação à interpolação para (a) ACCESS-CM2, (b) BCC-CSM2-MR, (c) CNRM-CM6-1-HR, (d) GFDL-ESM4, (e) INM-CM5, (f) MIROC6, (g) NorESM2-MM e (h) TaiESM1..	27
Figura 14. Variabilidade interanual da produtividade do feijão nas mesorregiões alagoanas.	29
Figura 15. Variabilidade interanual da produtividade do milho nas mesorregiões alagoanas..	29
Figura 16. Variabilidade interanual da produtividade da mandioca nas mesorregiões alagoanas..	30
Figura 17. (a) Climatologia da precipitação acumulada observada no período 1961-2014, (b) obtida a partir do ensemble de modelos do CMIP6 para 1974-2014, e (c) obtida a partir obtida do ensemble de modelos do CMIP6 para 1974-2014 após correção com ACC.....	31
Figura 18. Segundo semestre do ano: (a) Climatologia da precipitação acumulada interpolada no período 1961-2014, (b) obtida a partir do ensemble de modelos do CMIP6 para 1974-2014, e (c) obtida a partir obtida do ensemble de modelos do CMIP6 para 1974-2014 após correção com ACC.....	31
Figura 19. A cumulado médio anual de precipitação no NEB: (a) Climatologia da precipitação acumulada interpolada no período 1961-2014, (b) obtida a partir do ensemble de modelos do CMIP6 para 1974-2014, e (c) obtida a partir obtida do ensemble de modelos do CMIP6 para 1974-2014 após correção com ACC.....	32
Figura 20. Viés global da precipitação, em mm, do ensemble dos modelos em relação à observação antes da calibração com ACC (a), e após a calibração com ACC (b).	33
Figura 21. Correlação (r) da precipitação, em mm, do ensemble dos modelos em relação à observação antes da calibração com ACC (a), e após a calibração com ACC (b).	33
Figura 22. MAE da precipitação, em mm, do ensemble dos modelos em relação à observação antes da calibração com ACC (a), e após a calibração com ACC (b).	34
Figura 23. RMSE da precipitação, em mm, do ensemble dos modelos em relação à observação antes da calibração com ACC (a), e após a calibração com ACC (b).....	34

LISTA DE TABELAS

Tabela 1. Lista de modelos climáticos globais do CMIP6 usados neste estudo.....	15
Tabela 2. Preditor X e respectivos Preditados Y, para o passo 1 e passo 2 da pesquisa.	18
Tabela 3. Produtividade média do feijão, milho e mandioca nas mesorregiões de Alagoas no período de 1974-2014.....	28
Tabela 4. Parâmetros estatísticos obtidos a partir da simulação da produção das culturas nas mesorregiões alagoanas usando como variável preditora a precipitação observada no semestre AMJJAS. Valores de correlação em azul destacam a significância estatística.	36
Tabela 5. Parâmetros estatísticos obtidos a partir da simulação da produção das culturas nas mesorregiões alagoanas usando como variável preditora a precipitação original do modelo ACCESS-CM2. Valores de correlação em azul destacam a significância estatística.	36
Tabela 6. Parâmetros estatísticos obtidos a partir da simulação da produção das culturas nas mesorregiões alagoanas usando como variável preditora a precipitação do modelo ACCESS-CM2 após correção do viés com ACC. Valores de correlação em azul destacam a significância estatística..	37
Tabela 7. Número de simulações, de acordo com as mesorregiões, que apresentaram correlações significativas da produção quando comparadas a produção observada.	38
Tabela 8. Parâmetros estatísticos obtidos a partir da simulação da produção das culturas nas mesorregiões alagoanas usando como variável preditora a precipitação média dos modelos no semestre AMJJAS sem correção de viés da ACC. Valores de correlação em azul destacam a significância estatística.	38
Tabela 9. Parâmetros estatísticos obtidos a partir da simulação da produção das culturas nas mesorregiões alagoanas usando como variável preditora a precipitação média dos modelos no semestre AMJJAS com correção de viés da ACC. Valores de correlação em azul destacam a significância estatística.	39
Tabela 10. Parâmetros estatísticos obtidos a partir da média das simulações da produção das culturas nas mesorregiões alagoanas usando como variável preditora a precipitação média dos modelos no semestre AMJJAS sem correção de viés da ACC. Valores de correlação em azul destacam a significância estatística.	40
Tabela 11. Parâmetros estatísticos obtidos a partir da média das simulações oriundas dos modelos calibrados, no semestre AMJJAS. Valores de correlação em azul destacam a significância estatística.....	40

LISTA DE ABREVIATURAS

IPCC – Painel Intergovernamental de Mudanças Climáticas

NEB – Nordeste do Brasil

IBGE - Instituto Brasileiro de Geografia e Estatística

ACC – Análise de Correlações Canônicas

GEE – Emissão de Gases de Efeito Estufa

CMIP – Coupled Model Intercomparison Project

SSP – Shared Socioeconomic Pathways

RCPs – Representative Concentration Pathway

EMBRAPA – Empresa Brasileira de Pesquisas Agropecuária

CONAB – Companhia Nacional de Abastecimento

CC – Carga Normal

CCC – Carga de Cisalhamento Normal

ECMWF – European Centre for Medium-Range Weather Forecasts

CORDEX – Coordinated Regional Climate Downscaling Experiment

DCPP – Decadal Climate Prediction Project

INMET – Instituto Nacional de Meteorologia

ANA – Agência Nacional de Água e Saneamento Básico

IDW – Métodos de Ponderação de Distância Inversa

ADW – Ponderação de Distância Angular

SIDRA – Sistema de Recuperação Automática

SEALBA – Sergipe-Alagoas-Bahia

AMJJAS – Abril-Maio-Junho-Julho-Agosto-Setembro

CPT – Climate Predictability Tool

IRI – International Research Institute,

MCG – Modelos de circulação geral

TSM – Temperatura da Superfície do Mar

DJF – Dezembro-Janeiro-Fevereiro

JJA – Junho-Julho-Agosto

SON – Setembro-Outubro-Novembro

MAM – Março – Abril – Maio

SUMÁRIO

1. INTRODUÇÃO	1
2. OBJETIVOS	4
2.1 Geral	4
2.2 Específicos.....	4
3. REVISÃO DE LITERATURA	5
3.1 Clima	5
3.2 Mudanças climáticas.....	5
3.3 Análise de Correlações Canônicas (ACC).....	6
3.4 Modelos de clima	7
3.4.1 Modelos de clima na agricultura	8
3.5 Safras	9
3.5.1 Mandioca	9
3.5.2 Feijão	9
3.5.3 Milho	11
4. METODOLOGIA	12
4.1 Área de estudo	12
4.2 Análise de Correlações Canônicas (ACC).....	13
4.3 Modelos do CMIP6	14
4.4 Dados observados de precipitação.....	16
4.5 Dados de produtividade das culturas	17
4.6 Software CPT e modelo de previsão	17
4.7 Avaliação do desempenho do método	20
5. RESULTADOS	21
5.1 Simulação do clima presente	21
5.2 Análise de erros dos MCGs para o clima presente.....	24
5.3 Produtividade do milho, feijão e mandioca em Alagoas	28
5.4 Avaliação da correção de viés dos modelos do CMIP6 com ACC	30
5.5 Simulação da produção das culturas a partir da precipitação observada e estimada pelos modelos do CMIP6.	35
6. CONCLUSÕES	41
7. REFERENCIAS BIBLIOGRÁFICAS	42

1. INTRODUÇÃO

O aquecimento global é um dos maiores desafios ambientais da atualidade, ameaçando a produção de alimentos em escala global. De acordo com Angelo (2022), o aumento da frequência, intensidade e duração dos eventos climáticos extremos colocará diversos ecossistemas em risco elevado de perda de biodiversidade, impactando diretamente a agricultura. Para mitigar esses efeitos e antecipar cenários futuros, os modelos climáticos tornam-se ferramentas essenciais na análise das condições ambientais. Desenvolvidos por centros de pesquisa ao redor do mundo, esses modelos fornecem projeções fundamentais para a formulação de estratégias de adaptação e mitigação diante das mudanças climáticas.

As mudanças climáticas têm impactado significativamente a agricultura, comprometendo a produção de alimentos. Segundo o último relatório do Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2021), essas alterações já estão em curso. Estudos de Costa et al. (2020) indicam que a região Nordeste do Brasil (NEB) apresenta sinais claros de aquecimento e redução da precipitação. Além disso, as recorrentes secas tornam o NEB uma das regiões mais vulneráveis aos efeitos adversos das mudanças climáticas, exigindo medidas urgentes de adaptação e mitigação (da Rocha Júnior et al., 2020).

Neste contexto, localiza-se o estado de Alagoas, situado no leste do Nordeste do Brasil (NEB), que se caracteriza pela diversidade climática de suas três mesorregiões. O Leste, influenciado pela proximidade com o oceano, apresenta um clima mais úmido e temperaturas mais estáveis. O Sertão, por outro lado, registra baixos índices pluviométricos e temperaturas elevadas. Entre essas duas regiões, o Agreste funciona como uma zona de transição, refletindo características intermediárias de precipitação e temperatura (Silva et al., 2018).

O IPCC é um relatório global que aborda as mudanças climáticas em andamento, evidenciando que nenhuma região do planeta está imune aos seus efeitos, incluindo Alagoas. O aquecimento global e suas consequências já impactam a produção agrícola, levantando questionamentos sobre os desafios que o estado enfrentará no futuro. Diante desse cenário, uma análise dos impactos das mudanças climáticas na produção de alimentos em Alagoas torna-se essencial para o planejamento de estratégias de adaptação e mitigação.

Diante do exposto, este estudo visa regionalizar os cenários climáticos do sexto relatório do IPCC para Alagoas, a fim de avaliar os impactos das mudanças climáticas na produtividade das principais culturas agrícolas de subsistência do estado: feijão, milho e mandioca. Para isso, serão analisadas as relações entre a variabilidade da precipitação e a produtividade dessas

culturas, proporcionando uma compreensão mais precisa dos desafios climáticos e auxiliando no desenvolvimento de estratégias de adaptação.

Dada a importância social e econômica da agricultura de subsistência em Alagoas e a vulnerabilidade do estado às mudanças climáticas, esta pesquisa se justifica pela necessidade de desenvolver métodos preditivos robustos para compreender e antecipar os impactos da variabilidade da precipitação. Dessa forma, os resultados contribuirão para o aprimoramento dos modelos de previsão, permitindo a adoção de estratégias mais eficazes de adaptação e mitigação.

Para alcançar o objetivo principal deste projeto, serão analisadas previsões históricas de ciclo curto no estado de Alagoas, usufruindo dos modelos climáticos do CMIP6. Os dados foram obtidos de oito modelos climáticos globais que integraram o sexto relatório do IPCC: ACCESS-CM2 (Austrália), BCC-CSM2-MR (China), CNRM-CM6-1-HR (França), GFDL-ESM4 (EUA), MIROC6 (Japão), NorESM2-MM (Noruega), INM-CM5-0 (Rússia) e TaiESM1 (Taiwan). Após o reprocessamento e a calibração desses dados para as condições climáticas de Alagoas, foi possível comparar com as produtividades reais observadas entre 1974 e 2014, conforme dados do IBGE. Essa abordagem permitiu examinar as variabilidades climáticas históricas com a produção agrícola do estado. Assim, oferecendo um entendimento mais sólido de como o clima tem influenciado a colheita nas décadas anteriores.

A técnica de Análise de Correlações Canônicas (ACC) será empregada com duas finalidades principais. Primeiramente, servirá para calibrar as séries temporais mensais de precipitação estimadas pelos modelos climáticos no período de referência desta pesquisa (1974-2014). Para isso, a precipitação estimada pelos modelos será utilizada como preditor, enquanto a precipitação observada, derivada da análise gradeada de Xavier et al. (2022) para o NEB, será a variável predita. Após essa etapa de calibração, a nova base de dados de precipitação ajustada será utilizada para avaliar o potencial de previsibilidade da produtividade agrícola, no período histórico.

A ACC busca identificar e quantificar a associação entre dois grupos de variáveis, que no passo 1 dessa pesquisa será "precipitação dos modelos" x "precipitação observada", e no passo 2 será "precipitação calibrada dos modelos" x "produtividade". A ACC tem como foco buscar a correlação ótima entre uma combinação linear de variáveis em um dos grupos com uma outra combinação linear das variáveis do outro grupo de variáveis, determinando-se assim as combinações lineares dos dois grupos que possuem a maior correlação. Esse processo permite criar um modelo que pode ser usado tanto para ajustar uma determinada variável proveniente de uma determinada fonte em relação a observação verdadeira, e após isso usar

esse mesmo modelo para prever uma variável em um passo de tempo futuro (da Rocha Júnior et al., 2021).

Esta dissertação está estruturada em introdução: onde trata-se de mostrar o que será trabalhado, especificando o motivo e os objetivos; objetivos: referente aos objetivos do projeto, o que se pretende fazer e o que se espera do dito cujo; revisão literária: trabalhará os conceitos históricos do tema abordado; metodologia: descrição dos métodos aplicados; análise de resultados: examinar os resultados obtidos através do método aplicado; conclusão e as referências bibliográficas.

2. OBJETIVOS

2.1 Geral

Utilizar a técnica de ACC para previsão da produtividade das culturas de milho, mandioca e feijão para as mesorregiões do estado de Alagoas, examinando a relação entre a produção histórica (1974-2014) e a precipitação acumulada na estação de cultivo.

2.2 Específicos

- Avaliar o quão realistas são os diferentes modelos na simulação da precipitação do passado recente do NEB;
- Examinar as semelhanças e diferenças nas climatologias brutas dos modelos;
- Correlacionar o período de precipitação com a produção das safras;
- Avaliar o ganho real da previsão de safras a partir da precipitação de modelos do CMIP6 no período histórico antes e após correção do viés com ACC.

3. REVISÃO DE LITERATURA

3.1 Clima

Segundo Silva e Silva (2015), o clima pode ser descrito como uma sequência de eventos médios de tempo demarcando um espaço geográfico durante um intervalo de no mínimo 30 anos. Dessa forma, ele não pode ser descrito como estático, pois haverá mudanças significativas no tempo meteorológico ao longo do ano, o que torna difícil prever com precisão as condições. No entanto, ele pode ser medido em termos de condições médias, podendo variar significativamente de um ano para outro. Segundo Andrade e Basch (2012), o clima é um conjunto de elementos pertencente a meteorologia, que são variáveis com valores médios diferentes e por contribuir sobre situações climáticas agravantes. Por isso, para estimar o clima em uma determinada região é necessário que se estude por vários anos para estimar dados sobre o local.

Há diversas situações que contribuem para formação do tempo em um determinado setor, e que são consequências para composição do clima. A latitude, a altitude, a proximidade do mar, a presença de montanhas, a vegetação e a localização geográfica são alguns dos fatores que influenciam. Essas informações, segundo Andrade e Basch (2012), estão contidas nas Normais climatológicas. No entanto, é necessário analisar as escalas, como macro, meso e microclima.

Os fatores de macroclima estão ligados com as características climáticas de longas escalas (global ou regional). O mesoclima está ligado ao estudo do espaço em menor escala (Ribeiro, 1993). Já microclima, são os fatores que modificam o clima em pequena escala, ou seja, nas proximidades da superfície. Neste cenário é levado em consideração a atuação do homem no meio.

3.2 Mudanças climáticas

A mudança climática é um processo natural de alteração da temperatura da terra, que ocorre ao longo de milhares de anos. No entanto, nas últimas décadas o planeta está sofrendo mudanças em sua temperatura bem superior do que as causas naturais (Nobre et al., 2012). Muitos cientistas acreditam que a principal causa dessas mudanças é a emissão de gases de efeito estufa (GEE) resultante da atividade humana.

Todavia, com base em evidências científicas, existe hoje consenso sobre a forte contribuição da atividade humana para as alterações registadas nas últimas décadas. Esta influência antropogénica deriva, principalmente, das alterações na exploração e uso da terra (desflorestação, urbanização, desertificação, irrigação) e da crescente combustão de combustíveis fósseis (libertação de aerossóis e gases de estufa), com consequências diretas nos

equilíbrios radiativo e energético terrestres, às escalas local, regional e global. (ANDRADE, José; BASCH, Gottlieb, 2012, p. 42)

Apesar de ainda não haver uma clara noção do impacto dessas alterações na estabilidade do clima, é cada vez mais consensual que a atividade humana está contribuindo para um aquecimento global significativo. Assim, contra fatos não há arguição. Portanto, percebe-se que é visível a influência humana sobre as alterações climáticas. Essa influência humana está provocando alterações na concentração dos gases do efeito estufa na atmosfera, causando aumento de temperatura.

Existe o ambiente com a temperatura e a baixa oscilação térmica necessária para a vida na Terra. Trata-se de gases como o vapor d'água (H_2O), o gás carbônico (CO_2) e o metano (CH_4). No entanto, atividades humanas têm alterado a concentração destes gases na atmosfera, principalmente por converter estoques de carbono, como petróleo, carvão e florestas em CO_2 , por meio da combustão. (Klug et al., 2016, p.305)

Dessa forma, a concentração de CO_2 na atmosfera tem aumentado em ritmo acelerado nos últimos anos, devido ao uso de combustíveis fósseis, como petróleo e carvão, e da degradação da floresta amazônica. Apesar de ser invisível, o CO_2 é um dos gases responsáveis pelo efeito estufa, que impede a saída de calor do planeta. Assim, aumentando a temperatura do planeta, tal fenômeno é conhecido como aquecimento global.

O aumento da temperatura atmosférica pode elevar a taxa de respiração das plantas, afetando diretamente a eficiência fotossintética e o equilíbrio hídrico (Guarda et al., 2014). Como resultado, a planta perderá mais água para o ambiente, assim levando-a ao estresse hídrico. Segundo Guarda et al. (2014), a consequência disso é a redução da sua produção, interferindo em seu crescimento e, em casos extremos, até a morte da planta.

Perante a este quadro, faz-se necessário executar modelos climáticos, tendo em vista que eles são de suma importância, pois geram informações futurísticas do que poderá acontecer em nível global ou regional. No entanto, é importante mencionar no trabalho as estatísticas usadas pelos modelos.

3.3 Análise de Correlações Canônicas (ACC)

A ACC é uma técnica estatística multivariada usada para examinar as relações entre duas ou mais variáveis em diferentes conjuntos de dados, identificando combinações lineares dessas variáveis que exibem a melhor interação funcional entre duas combinações (Peixoto, 2021). A ACC é frequentemente usada ao tentar entender a relação entre dois conjuntos de

variáveis que podem estar relacionadas, mas não são diretamente observáveis como entidades separadas.

A análise de correlação canônica (ACC) é um procedimento estatístico que permite examinar as relações entre duas ou mais variáveis dependentes com múltiplas variáveis independentes. A ACC sobressai quando comparada com a regressão linear múltipla, que modela uma variável dependente com várias variáveis independentes, pois a análise de correlação canônica permite explorar as múltiplas relações entre os conjuntos de variáveis (Peixoto, 2021 apud Wilks, 2011; Singh et al., 2012).

A aplicabilidade dessa técnica se dá em diversas áreas de estudos. Mas vale ressaltar aqui que ela vem se tornando destaque nas últimas décadas. Tornando-se referência na previsão climática, principalmente em relação a sazonalidade, por exemplo (da Rocha Júnior et al., 2021; Ham e Jeong., 2021; Miller et al., 2021; Ordoñez et al., 2022). A aplicação dessa técnica se torna útil na indústria agrícola em regiões onde a temperatura da superfície do mar e a precipitação é mais direta, como é o caso do nordeste brasileiro, podendo-se desenvolver modelos usando ACC para previsão de safras (Peixoto, 2021).

3.4 Modelos de clima

Os modelos climáticos são ferramentas computacionais que simulam a evolução da atmosfera e dos oceanos ao longo do tempo. Esses modelos são importantes para entender e prever os efeitos do aquecimento global, baseando-se em leis de conservação de massa, energia e momento. (Meehl et al., 2000).

Mesmo com os avanços tecnológicos, tornando os modelos atuais com mais variáveis, as projeções de aumento de temperatura nos modelos contemporâneos são muito parecidas com as antigas. Assim, todos eles mostram um aumento significativo da temperatura na Terra nos próximos anos (Firpo et al., 2022; Monteverde et al., 2022).

A iniciativa para criação dos modelos matemáticos começa no ano de 1995, quando cientistas de diversas Universidades se unem e criam um projeto chamado CMIP (*Coupled Model Intercomparison Project*) (Meehl et al., 2000). Uma ferramenta muito útil e de baixo custo, além da sua alta precisão. Os modelos são ferramentas de suma importância, tendo em vista que são o alicerce do IPCC, que analisa as informações para em seguida publicar seus relatórios de avaliação.

No presente momento, há seis fases do CMIP. Cada uma delas representam um cenário futurista e seus impactos climáticos. No entanto, os modelos CMIP3 e CMIP5 são os mais utilizados. O CMIP6 é a fase atual (Eyring et al., 2016). O CMIP3 está relacionado com cenários de gases do efeito estufa. Já o CMIP5 representa os cenários de expansão de energia em nível

global, enquanto o CMIP6 engloba os cenários conhecido como SSP (*Shared Socioeconomic Pathways*), que continua usando cenários de expansão no sistema de energia global, ou seja, é uma versão mais completa do modelo anterior.

Os cenários usados no CMIP, também passaram por um processo evolutivo. Os primeiros cenários tinham a capacidade de analisar 4 caminhos possíveis de emissões de GEE. Na atualidade, os cenários estão bem desenvolvidos, que são chamados de RCPs (*representative concentration pathway*) e SSPs (*shared socioeconomic pathway*), vale ressaltar que este último é o mais avançado, ou seja, é o mais atual (Masson-Delmotte et al., 2021). Os cenários analisam os gases do efeito estufa assumindo concentrações distintas dos mesmos, reportando diferentes usos de uma forçante radioativa (Ortega et al., 2021). Os cenários SSPs são complementos dos RCPs. Tendo como principal função realizar diferentes estimativas de cenários de emissões de GEE correlacionando-as com políticas públicas distintas (Almazroui et al., 2021a-b, Llopart et al., 2021, Lv et al., 2021).

3.4.1 Modelos de clima na agricultura

A modelagem climática para a agricultura é um processo iterativo, no qual são avaliadas as simulações de crescimento e desenvolvimento da vegetação com dados de precipitação, temperatura, umidade relativa ar, entre outros, geralmente fazendo-se uso de informações das estações meteorológicas próxima a área que se pretende estudar (ou dados de satélites).

Além disso, essa modelagem se comporta como uma ferramenta muito importante, no que se refere as alterações climáticas, visto que tem a capacidade de auxiliar nessas alterações visando a vegetação. De acordo com Almeida (2021) estes modelos se apresentam de forma que:

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 (Almeida, 2021, p.20).

Dessa forma, as equações levarão a resultados que poderão prever o desenvolvimento das plantas, e obviamente será constatado informações produtivas consoante com os fatores agravantes (Oliveira et al., 2021; Lima et al., 2021). Portanto, a modelagem matemática é uma ferramenta essencial para a agricultura, pois permite antecipar o desempenho das plantas em função de diversos fatores, inclusive a precipitação, que o é a variável analisada no presente trabalho.

3.5 Safras

A agricultura é uma atividade econômica que está diretamente ligada à produção de alimentos. Diante disso, este tópico fala sobre as produções agrícolas, como as safras de feijão, milho e mandioca.

3.5.1 Mandioca

A mandioca é uma planta anciã que tem sua origem na América do sul, e o seu cultivo era realizado pelos povos nativos da região tropical do continente (EMBRAPA, 2020). Assim, desde os primórdios até atualidade está sendo mantida a sua produção, principalmente no território brasileiro, onde é cultivada em todo país. Tornando-se uma das maiores socioeconômicas nacional.

A confluência maior no Brasil está localizada na região do NEB. Boa parte da produção de mandioca no NEB é realizada no semiárido, este que ocupa a faixa territorial de 982.563 km², segundo o Embrapa (2020). Dessa área, oito estados do NEB estão com diferentes proporções de terras, equivalente a valores maiores que 50% e menores que 60% (EMBRAPA, 2020). No entanto, esse estudo acontece no estado de Alagoas, onde a produção é menor de 5%.

No semiárido, a temperatura é alta, variando entre 20 °C e acima de 27 °C. Para a germinação da mandioca, a temperatura ideal é entre 20 a 27 °C, valores fora deste intervalo podem atrasar o desenvolvimento da cultura (EMBRAPA, 2020). Desse modo, Alagoas possui condições climáticas adequadas para o plantio da mandioca, pois a mesma faz parte do semiárido brasileiro, possuindo temperaturas elevadas.

No semiárido, a produção de culturas de ciclo curto é predominante, pelas suas características (EMBRAPA, 2020). Por isso é importante ficar atento a safra de mandioca, pois o seu ciclo é anual. Assim, é de suma importância adequar à época de chuvas, no início do cultivo não pode haver falhas, pois poderão levar a sérios prejuízos na produção da mandioca. Portanto, em geral, a melhor época do ano para o plantio é na estação chuvosa, de modo que a umidade e calor sejam elementos de suma importância para brotar, enraizar e estabilização das plantas no solo. Dessa forma, o melhor período para o plantio em Alagoas é de maio a junho.

3.5.2 Feijão

Apesar de ser uma cultura sensível ao estresse hídrico, o feijoeiro é cultivado em quase todas as regiões do Brasil, principalmente em lavouras de pequeno e médio porte. O Brasil é um dos países com maior consumo e produção de feijão no planeta. No ano de 2020 a CONAB, disponibilizou dados estimados sobre a primeira safra do ano, que é mais de um milhão de

toneladas, assim tendo um saldo superior, 6,1%, em relação ao ano anterior. As demais safras (segunda e terceira) tiveram um aumento de 2,5%.

O feijão é um alimento de grande importância no cenário econômico, além das suas taxas nutricionais excelentes. Ele é um provimento básico, que se torna importante principalmente para classe baixa. De tal forma, o dito cujo é substancial na mesa da população brasileiras.

O feijoeiro apresenta ciclo curto que dura em média de 90 dias. Suas fases de desenvolvimentos estão divididas em 10 (Oliveira e Silva, 1990): germinação (V0); emergência (V1), folhas primárias (V2), primeira folha composta aberta (V3), terceira folha trifoliolada aberta (V4), pré-floração (R5), floração (R6), formação de vagens (R7), enchimento das vagens (R8) e maturação (R9).

A fase inicial V0, como o próprio nome diz, é o início de tudo, ou seja, é onde começa a sementeira, assim iniciando a germinação. Já a V1, inicia-se quando os cotilédones se tornam visíveis e termina quando as folhas primárias se separam e se abrem. A V2 se estabiliza na posição horizontal. V3 e V4, é o momento em que as folhas estão abertas completamente. A reprodução é iniciada na R5, nas R6 e R7 a vagem é visível. No R8 a vagem se estabiliza em comprimento e em R9 é o processo de colheita.

Vale ressaltar que o feijão é uma planta que tem seu desenvolvimento de fácil adaptação a temperatura local. Podendo-se desenvolver entre temperaturas de 18 a 30 °C. no entanto, com temperaturas maiores que 35 °C, há uma queda de produtividade. Outro ponto que deve ser destacado também é que abaixo de 15 °C a evolução é retardada do feijoeiro (Guerra et al., 2000; Hodges et al., 2004; Bennel et al., 2007).

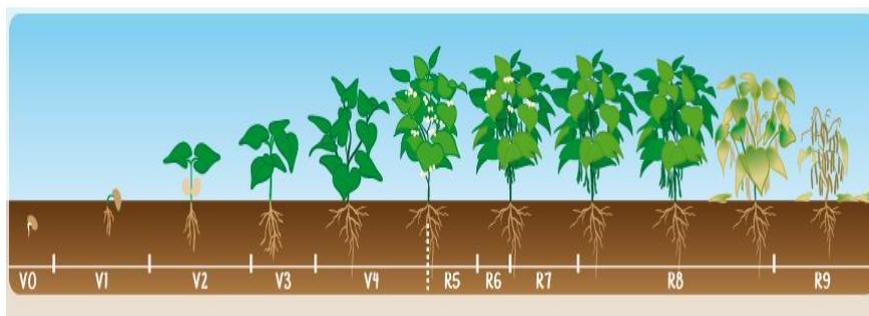


Figura 1. Fases do desenvolvimento do feijoeiro. Fonte: EMBRAPA.

Vale ressaltar aqui que o período de safra do feijão está dividido em três, cada uma delas é aplicada em cada estado do Brasil. Em Alagoas, objeto de estudo do presente trabalho, o período de plantio a coleta tem duração em média de 7 meses (como mostra a figura 2 abaixo), iniciando em abril e concluído em outubro, sendo assim a terceira safra, segundo a CONAB.

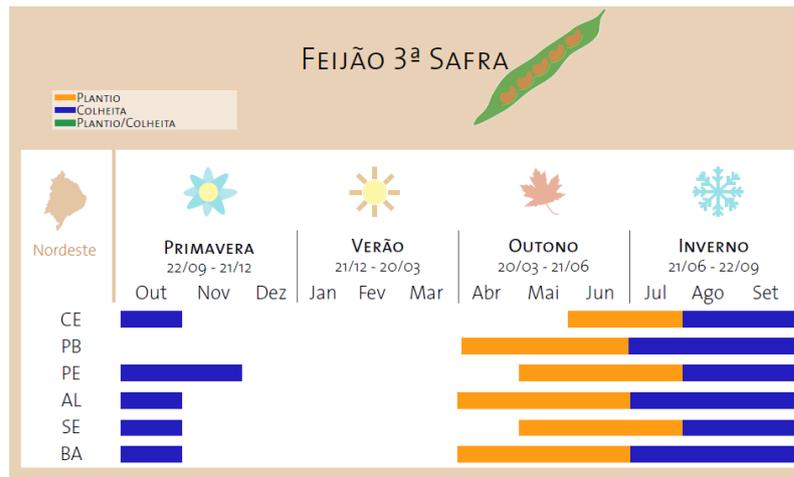


Figura 2. Terceira safra de feijão. Fonte: CONAB.

3.5.3 Milho

O milho é uma das safras que é plantada em quase todo território nacional. Assim, tornando-se de grande importância socioeconômica. A cultura dessa planta é bastante resistente à seca e apresenta boa produtividade, o que a torna uma das principais culturas da região Nordeste. Ela se mostra resistente ao estresse hídrico, o que a torna uma cultura de grande importância em regiões de escassez de água. Em 2006, o milho produzido na região do NEB representava 13% da produção em todo o Brasil (Araújo et al., 2014). Dentro de sua classe, o milho é uma das plantas que possuem alta produção, sendo cultivada em diversas regiões do mundo (Martins et al., 2012). O milho constitui uma atividade econômica relevante, principalmente, para estados como Alagoas e Bahia, que, em 2006, eram os seus principais produtores da região Nordeste (Araújo et al., 2014, p.47).

O milho pode ser cultivado em regiões onde a temperatura média anual é de 10 °C a 30 °C, com necessidade hídrica de 600 mm. Ele é uma planta anual, cujo ciclo fenológico é favorecido em temperaturas mais elevadas (sendo assim bastante relevante sua produção em Alagoas). A Figura 3 mostra o período de safra no estado de Alagoas. Como se pode notar, a produção de milho no estado está conectada com a segunda safra. Todo o período vai de abril, início do plantio, a dezembro, fim da colheita. Portanto, a melhor época do ano para o plantio em Alagoas é na estação de outono, ou seja, em abril. Esta planta está inserida no grupo das plantas chamadas de C4. Segundo Martins (2012, p.21), este tipo de metabolismo consegue atingir alta performance quando alcança seu ápice de área foliar (Pereira e Machado, 1987). Isso acontece porque a produtividade de milho é influenciada diretamente pela quantidade de luz que a planta recebe.

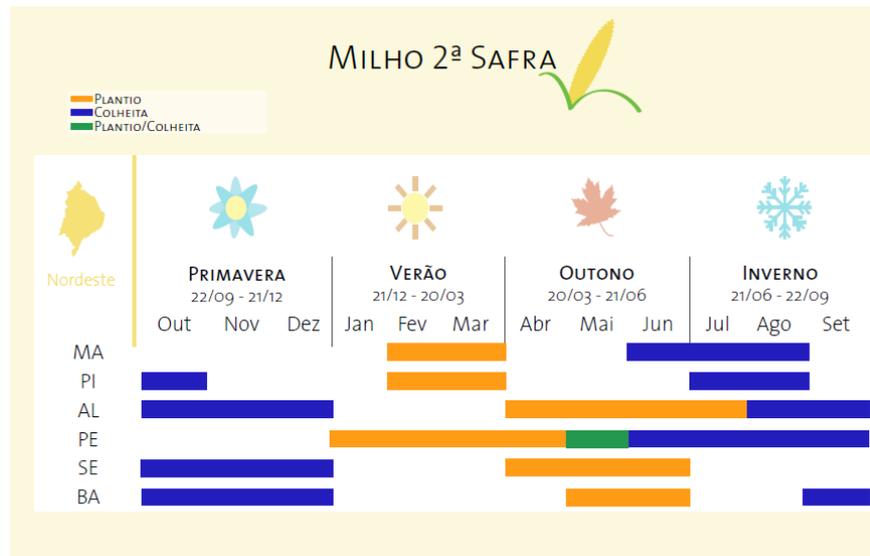


Figura 3. Safra do Milho. Fonte: CONAB.

4. METODOLOGIA

4.1 Área de estudo

Área de estudo dessa pesquisa se divide em duas, o NEB para avaliação geral dos modelos do CMIP6, e o estado de Alagoas para simulação da produtividade das culturas. Alagoas está situado no leste do NEB. O estado possui uma área de mais de 27.000 km², (IBGE, 2002, apud BARROS et al., 2012). Seu território está limitado entre os estados de Pernambuco, Sergipe e Bahia. Ele está dividido em três mesorregiões: leste alagoano, agreste alagoano e sertão alagoano (IBGE, 2010, apud BARROS et al., 2012). O leste alagoano é a região úmida do estado, o agreste é uma zona de transição entre úmida e seca, e o sertão é a região seca do estado, de clima árido e semiárido. Conforme Barros et al. (2012), a localização do estado faz com que ele possua um clima irregular de chuvas, variação escassa de sazonalidade da radiação solar, fotoperíodo e de mudanças de temperatura do ar. A sua proximidade a linha do equador faz com que ele esteja submetido a mais horas de incidência solar, assim fazendo com que aconteça maior evapotranspiração.

A Figura 4 mostra o NEB com destaque para Alagoas, nas figuras além dos limites regional e estadual, observam-se os pontos de observações que foram usados para calibração da precipitação mensal dos modelos do CMIP6 no NEB e os respectivos pontos em Alagoas usados para as simulações da produtividade das culturas. Tópicos específicos sobre a descrição dos dados usados vêm na sequência dessa seção.

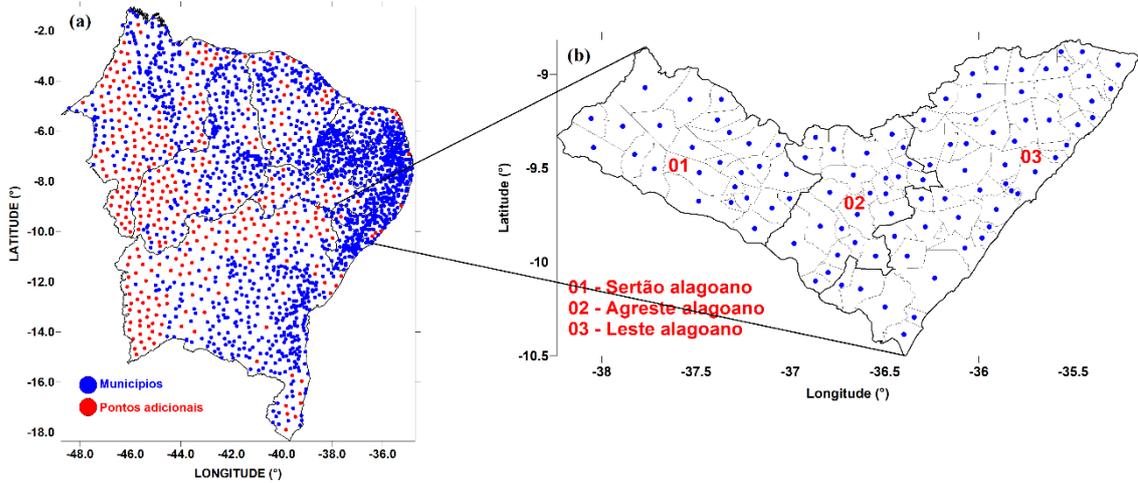


Figura 4. (a) NEB e (b) Alagoas, com suas três mesorregiões com os respectivos municípios, cujos centroides (pontos azuis), serviram de referência para a construção do banco de dados de precipitação extraída de Xavier et al. (2022).

4.2 Análise de Correlações Canônicas (ACC)

A ACC não era uma técnica estatística muito utilizada até o avanço tecnológico que possibilitou o desenvolvimento de programas computacionais, tornando-se bem mais usada em diversas áreas da ciência, como na agrometeorologia para a previsão de safras. O objetivo do ACC é encontrar um modelo linear que melhor se ajusta às observações de dados.

Na ACC, há combinações lineares x^* e y^* , que corresponde as variáveis canônicas:

$$x^* = X\alpha = \sum_{i=1}^p \alpha_i x_i; y^* = Y\beta = \sum_{j=1}^q \beta_j y_j \quad (1)$$

Na equação (1), X e Y são variáveis dependente e independente, respectivamente. α e β são vetores que maximizam a correlação. E cada correlação canônica deve estar ligada a variância e não relacionada a outras correlações canônicas:

$$Corr[x_k^* y_M^*] = \begin{cases} r_c, k = M \\ 0, k \neq M \end{cases} \quad (2)$$

Sabendo que r_c é a correlação canônica; a determinação das variáveis aleatórias é feita através das matrizes de variâncias e covariâncias,

$$[S_c] = \begin{bmatrix} [S_{xx}](p \times p) & [S_{xy}](p \times q) \\ [S_{yx}](q \times p) & [S_{yy}](q \times q) \end{bmatrix} \quad (3)$$

Sabendo que $[S_{xx}]$ e $[S_{yy}]$ são matrizes de variância e covariância respectivamente de p variáveis em X e as q variáveis em Y . Já $[S_{xy}]$ e $[S_{yx}]$ são covariantes entre os elementos X e Y , respectivamente. A raiz quadrada dos valores integrais, que é diferente de zero nas matrizes, fornecem as correlações canônicas, r_c , entre as variáveis canônicas.

$$[M_x] = [S_{xx}]^{-1}[S_{xy}][S_{yy}]^{-1}[S_{yx}] \quad (4)$$

$$[M_y] = [S_{yy}]^{-1}[S_{yx}][S_{xx}]^{-1}[S_{xy}] \quad (5)$$

Seja α e β vetores que satisfazem a matriz, então se tem

$$[M_x]\alpha = r_c^2 \alpha \quad (6)$$

$$[M_y]\beta = r_c^2 \beta \quad (7)$$

Ao construir modelos preditivos, os valores de α e β indicam quais variáveis na correlação têm mais poder explicativo (Wilks, 2011; Singh et al., 2012). A carga normal (CC) e a carga de cisalhamento normal (CCC) também são calculadas aqui. A correlação linear entre x_i e x^* é independente de CC, e a correlação entre y_i e y^* é dependente de CC. Os coeficientes de redundância são calculados na ACC e permitem que a porcentagem de variância explicativa em uma combinação de variáveis dependentes seja determinada a partir de uma combinação de variáveis independentes (Katz et al., 2003). A ACC foi escolhida como método de previsão por ser um dos métodos menos dependentes da periodicidade dos fenômenos climáticos. Além disso, o uso dessa metodologia parece ser menos dependente de fenômenos climáticos cíclicos, pois os objetivos da pesquisa são avaliados a partir de resultados que variam em múltiplas escalas de tempo. Além disso, o uso dessa metodologia é considerado adequado, pois os objetivos da pesquisa são avaliados por meio de resultados que variam em várias escalas de tempo.

Este trabalho faz uso da ACC como ferramenta para relacionar a precipitação acumulada mensalmente, trimestral, semestral, anual e a produtividade observada do feijão, mandioca e milho em quilogramas por hectares, em Alagoas como histórico produtivo disponível no IBGE. O período de calibração é de 1974 a 2014.

4.3 Modelos do CMIP6

Nessa pesquisa, usou-se dados históricos de precipitação de 8 modelos climáticos obtidas no repositório do *climate data store* pertencente ao projeto *copernicus* mantido pelo ECMWF (*European Centre for Medium-Range Weather Forecasts*), no seguinte link: <https://cds.climate.copernicus.eu/cdsapp#!/dataset/projections-cmip6?tab=form>.

A tabela abaixo mostra os respectivos modelos que estão sendo utilizado e informações, tais como, nome do modelo, país de origem e resolução atmosférica. Estes modelos foram escolhidos pela sua eficiência em reproduzir características gerais da variável precipitação (Dantas et al., 2022). É importante frisar aqui que os resultados desses modelos são o valor final

proveniente de seus *ensembles*, ou seja, do conjunto final de todas as simulações de todos os membros do modelo.

Tabela 1. Lista de modelos climáticos globais do CMIP6 usados neste estudo.

Ordem	Nome do modelo	Instituto/País	Resolução Atmosférica (lon × lat em graus)
1	ACCESS-CM2	CSIRO-ARCCSS/Austrália	1.9° × 1.3°
2	BCC-CSM2-MR	BCC/China	1.1° × 1.1°
3	CNRM-CM6-1-HR	CNRM-CERFACS/França	0.5° × 0.5°
4	GFDL-ESM4	GFDL/Estados Unidos	1.0° × 1.0°
5	MIROC6	MIROC/Japão	1.4° × 1.4°
6	NORESM2-MM	NCC/Noruega	1.0° × 1.0°
7	INM-CM5-0	INM/Rússia	2.0° × 1.5°
8	TaiESM1	NCHC/Taiwan	1.3° × 0.9°

Os modelos do CMIP6 são executados e disponibilizam dois “experimentos”, um período de referência histórico para comparação com cenários futuros, de 1850 a 2014, e experimentos de projeção climática seguindo os cenários SSP, fornecendo diferentes caminhos para o forçamento climático futuro. O período abrangido é tipicamente 2015-2100 (Eyring et al., 2016).

Nessa pesquisa, serão usados apenas dados de precipitação do período de referência dos modelos para investigar sua correlação com a precipitação observada e como pode ser a simulação da produção de culturas de ciclo curto em Alagoas a partir da precipitação desses modelos. Mesmo não usando dados dos cenários futuros, a título de conhecimento, descreve-se brevemente a seguir os principais cenários do CMIP6, os SSPs 2.6; 4.5; 6.0; 7.0 e 8.5, de acordo com O’Neill et al. (2016).

SSP1-2.6: este cenário representa o limite inferior do intervalo de caminhos de forçamento futuros na literatura científica e atualiza o cenário RCP2.6 do CMIP5. Prevê-se que produzirá uma média multimodelo de aquecimento significativamente inferior a 2 °C até 2100 e, portanto, pode apoiar as análises de mudanças substanciais no uso da terra (em particular, aumento da cobertura florestal global). Do ponto de vista otimista, este cenário é altamente relevante, pois combina baixa vulnerabilidade com baixos desafios para mitigação, bem como um sinal de baixo forçamento radiativo.

SSP2-4.5: este cenário representa a parte média do intervalo de caminhos de forçamento futuros e atualiza o cenário RCP4.5. Ele é usado como um experimento de referência, por

exemplo, pelo *Coordinated Regional Climate Downscaling Experiment* (CORDEX) para *downscaling regional*, pelo *Decadal Climate Prediction Project* (DCPP) para previsões de curto prazo até 2030, e pelo *Detection and Attribution MIP* (DAMIP) como uma continuação das simulações históricas para atualizar as estimativas baseadas em regressão do papel das forçantes únicas além de 2015 e para executar experimentos de forçamento únicos no futuro, usando-o como cenário de referência. Nesse cenário o uso da terra e trajetórias de aerossóis não são extremos em relação a outros cenários, sendo relevante também por ser um cenário que combina vulnerabilidade com um nível de forçamento intermediário.

SSP4-6.0: este cenário preenche o intervalo de cenários de forçamento médio e atualiza o cenário RCP6.0. Esse cenário pode ser usado para investigar as diferenças nos impactos dos cenários de forçamento da média global, mesmo que os efeitos climáticos regionais do uso da terra e dos aerossóis se mostrem fortes.

SSP3-7.0: este cenário representa a extremidade média a alta da faixa de cenários de forçamento futuros. Ele preenche uma lacuna nos caminhos de forçamento do CMIP5 que é particularmente importante porque representa um nível de forçamento semelhante ao do cenário de linha de base do SSP2. Cenários de linha de base são muito importantes para estudos interessados em quantificar impactos, vulnerabilidade e adaptação. Esse é um cenário com mudanças substanciais no uso da terra (em particular diminuição da cobertura florestal global) e altas emissões de gases (particularmente SO₂, aerossóis, precursores troposféricos de O₃ e CH₄) e, portanto, desempenha um papel importante abordando questões relevantes sobre a sensibilidade do clima regional ao uso da terra e aos aerossóis.

SSP5-8.5: este cenário representa o limite superior da gama de caminhos futuros de emissões, atualiza o cenário RCP8.5 e está planejado para ser usado por vários outros projetos de intercomparação de modelos para ajudar a abordar suas questões científicas. O SSP5 foi escolhido para este caminho de forçamento porque é o único cenário SSP com emissões altas o suficiente para produzir um forçamento radiativo de 8,5 W m⁻² em 2100.

4.4 Dados interpolado de precipitação

Foi utilizado o banco de dados estimado de Xavier et al (2022) para o estado de Alagoas. Esses dados foram alcançados graças ao método da interpolação, que estima valores entre dois pontos, que foi usado para desenvolver grades de alta resolução de variáveis climáticas de 1974 a 2003. Neste trabalho, o elemento climático em questão é a precipitação. Vale ressaltar que a escala temporal utilizada foi a de precipitação mensal.

Desde 2016, Xavier et al. (2016) lançaram um conjunto de dados meteorológicos de análise gradeada referente ao período 1980-2013 a fim de prover informações de diversas

variáveis para todo o território brasileiro. Essa grade tem resolução espacial de $0,25^\circ \times 0,25^\circ$ e foi utilizada em diversos estudos como base confiável de observação da superfície (da Rocha Jr et al, 2019; Paredes-Trejo et al, 2019; Silva et al, 2019; Campelo et al, 2020; Silva et al, 2023).

Contudo, Xavier et al. (2022) atualizaram essa análise gradeada tanto na resolução temporal, de 1961 até 2020, quanto na espacial com $0,1^\circ \times 0,1^\circ$. Em relação à precipitação, essa foi a variável que contou com a maior quantidade de observações de superfície para a construção da grade, com um incremento de 316% de postos pluviométricos a mais do que na análise disponibilizada para 1980-2013. A maior parte dos dados pluviométricos foram oriundos do INMET, ANA e agencias estaduais de Meteorologia espalhadas pelos estados brasileiros. Como descrito em seu trabalho, os dados foram expostos a um rigoroso controle de qualidade e em seguida interpolados seguindo os melhores resultados obtida via validação cruzada entre os métodos de ponderação de distância inversa (IDW) e ponderação de distância angular (ADW), para geração de uma grade em alta resolução de $0,1^\circ \times 0,1^\circ$.

Para cada mesorregião de Alagoas foi identificado o semestre mais chuvoso, que compreendem a estação de cultivo das culturas de milho e feijão, duas culturas de ciclo curto que duram, em média 120 e 90 dias. Para as três mesorregiões esse semestre mais chuvoso se dá de abril a setembro. Para atender a cultura da mandioca, que é anual, utilizar-se-á o total pluviométrico anual.

4.5 Dados de produtividade das culturas

Os dados de produtividade foram coletados do Banco de Dados Estatístico do Sistema de Recuperação Automática (SIDRA) do Instituto Brasileiro de Geografia e Estatística (IBGE), para o período de 1974 a 2014.

Todavia, a base de dados pluviométrica e de produtividade foi trabalhada para um período em comum a fim de eliminar problemas de continuidade observados no final das séries de produtividade do milho para as mesorregiões do agreste e leste alagoanos, devido ao efeito “SEALBA”, como descrito em Silva et al. (2022), que se trata da intensificação da irrigação em culturas de grãos como o milho elevando sobremaneira a taxa de produtividade, não permitindo inferir a relação direta entre produtividade e influencia climática.

4.6 Software CPT e modelo de previsão

Como explicado anteriormente, a ACC será utilizada em duas etapas, na primeira a precipitação mensal de cada modelo do CMIP6 é confrontada a precipitação observada¹, de

¹ O termo utilizado faz referência aos dados interpolados de Xavier et al (2022)

forma a se construir um modelo matemático de regressão baseado em correlações canônicas que reamostre a precipitação mensal dos modelos de acordo com a aprendizagem imposta pela ACC. No segundo passo, os dados mensais de chuva dos modelos após a reamostragem são organizados como séries temporais acumuladas semestralmente para os seguintes períodos: abril a setembro (AMJJAS) e anual, ou seja, utiliza-se uma série do acumulado semestral de abril a setembro para compreender toda a estação de cultivo para o milho e feijão, e a série acumulada anual para compreender a maior parte da estação de cultivo da mandioca. Segundo Stevens e Ruscher (2014), esta forma de organizar os dados maximiza a possibilidade de encontrar relações entre a precipitação acumulada e a produtividade da cultura em cada ano utilizado para *hindcast*, entre 1974 a 2014.

A Tabela 2 mostra a relação entre preditor², que chamamos de variável X, e preditando³, que chamamos de variável Y na ACC, para o passo 1 e passo 2.

Tabela 2. Preditor X e respectivos Preditados Y, para o passo 1 e passo 2 da pesquisa.

Passo 1	
Preditor (X)	Preditando (Y)
chuva mensal estimada pelos modelos	chuva mensal observada
Passo 2	
Preditor (X)	Preditando (Y)
chuva acumulada no semestre AMJJAS	produção do feijão e milho de cada mesorregião
chuva acumulada anual	produtividade da mandioca de cada mesorregião

O software utilizado para realizar os cálculos matemáticos da ACC será o CPT (*Climate Predictability Tool*), desenvolvido pelo *International Research Institute for Climate and Society* (IRI, 2006). Trata-se de um software livre disponível para as plataformas windows, linux e python, e que pode ser encontrado em sua versão mais recente no seguinte endereço eletrônico: <https://iri.columbia.edu/our-expertise/climate/tools/cpt/>.

A ACC é uma entre as muitas funcionalidades do CPT, que permite realizar correções estatísticas de previsões climáticas de modelos de circulação geral (MCG), ou produzir previsões usando campos de TSM ou de preditores semelhantes (altura geopotencial e componentes do vento em diversos níveis, por exemplo), além de possuir um módulo de regressão por componentes principais e regressão linear múltipla.

A ACC é amplamente utilizada para gerar previsões climáticas operacionais (Barnston e Tippett., 2017; Esquivel et al., 2018; Hossain et al., 2019). No CPT, a ACC pode ser usada

² Esta palavra faz referência ao termo *predictor*

³ Esta palavra faz referência ao termo *predictand*

de duas formas (ver a Figura 1 de Barnston e Tippett, 2017), a primeira e que será utilizada no passo 1 dessa pesquisa é relacionar saídas brutas de modelos dinâmicos às observações, por exemplo, precipitação acumulada prevista de um mês/trimestre relativo a um período de referência passado (hindcast) com as observações reais desse período, e assim recalibrar e corrigir vieses nessas previsões, permitindo aplicar essa correção às futuras previsões dos modelos. A segunda forma, e utilizada no passo 2 dessa pesquisa, é construir um modelo de previsão puramente estatístico, relacionando um preditor a um preeditando, em nosso caso, campos de precipitação calibrada dos modelos com dados de produção das culturas nas mesorregiões de Alagoas. Esta metodologia é similar à previsão sazonal com ACC relacionando TSM (preditor) com a precipitação (preeditando).

Totais de precipitação do semestre AMJJAS e anual, serão os preditores (X), e a produção média do milho, feijão e mandioca de cada mesorregião de Alagoas os preeditandos (Y). Ambos os campos são pré-filtrados com Funções Ortogonais Empíricas (FOE) para eliminar ruídos dos dados originais (Barnston e Tippett, 2017). Nesse processo, as FOE de X e Y são calculadas separadamente, estabelecendo-se um modelo que retenha em torno de 70% a 80% da variância original de cada variável a partir de um número de autovetores. Esse processo força a ACC a enfatizar os modos de variabilidade dominantes de X e Y. Em seguida, uma matriz de correlação cruzada é construída com as séries das componentes principais de X e Y, que tem suas dimensões reduzidas ao número de modos retidos pelo preditor e pelo preeditando, obtendo-se autovetores e autovalores canônicos para X e Y dessa matriz transposta.

Encontra-se a função canônica do preditor a partir das combinações lineares entre os autovetores canônicos e as séries das componentes principais do preditor para cada modo. Apesar de poder-se utilizar um número limitado de modos baseado na análise de explicação da variância, recomenda-se estabelecer como limites para o software um mínimo de 1 modo até um máximo de 10 modos, isto é recomendável pois permite que o mesmo encontre de forma automatizada o número ótimo de modos baseado em um coeficiente de bondade do modelo (*goodness index*), esse índice ajusta o número de modos de acordo com a correlação obtida a partir da testagem de vários modelos com diferentes combinações de modos para X e Y, o que geralmente limita o número de modos entre 3 a 6, respectivamente. A equação de regressão expressa pelos modos canônicos deriva das variáveis originais, convertendo-se a função temporal canônica do preditor em função temporal canônica do preeditando.

Por fim, a equação preditiva é obtida para relacionar preditor ao preeditando, ou X a Y, e as simulações históricas e/ou previsões, podem ser realizadas. Essa pesquisa se ateve a simulações históricas da precipitação para o passo 1, e para previsões no passo 2. A Figura 5

ilustra de forma esquemática as etapas necessárias para as simulações da produção (preeditando Y) em função dos campos de precipitação acumulada semestrais (preditor X).

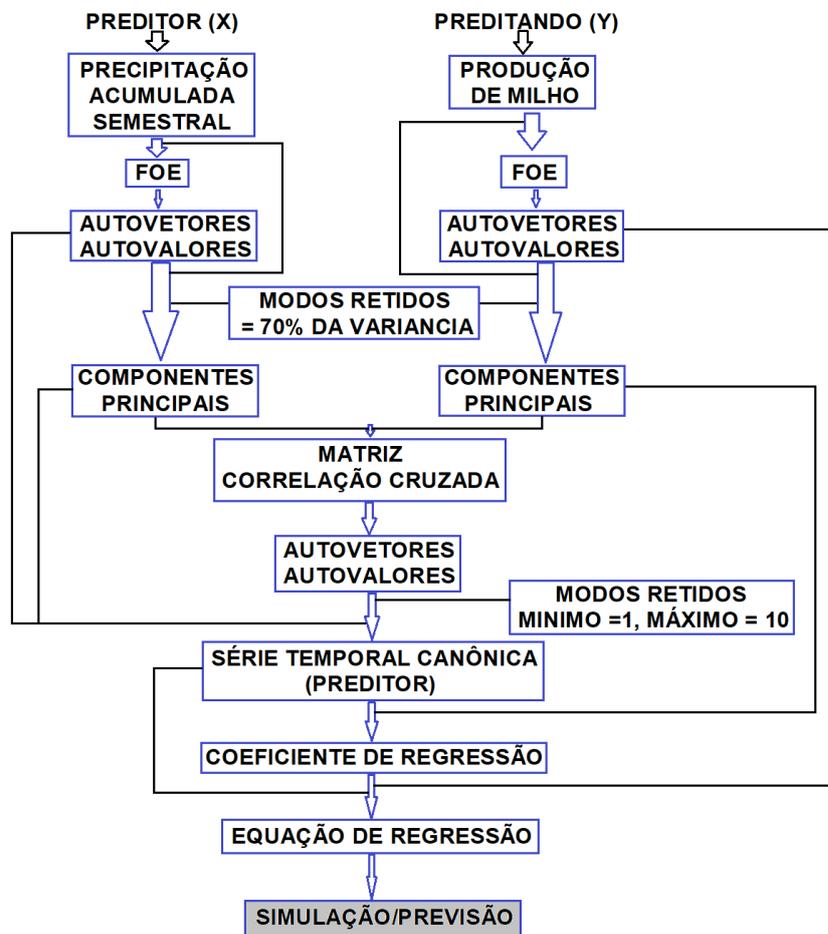


Figura 5. Esquema ilustrativo das etapas utilizadas para as simulações da produtividade das culturas nas mesorregiões do NEB a partir da precipitação acumulada semestral e anual. No esquema, usa-se o milho para exemplificação (Autor, 2011).

4.7 Avaliação do desempenho do método

No referido trabalho, será utilizado alguns métodos estatísticos descritos por Hofstra et al., (2008) e Xavier et al., (2016) para comparar os dados dos modelos versus interpolados, assim como o desempenho dos modelos após a calibração com ACC. Sejam eles:

$$R = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n \sqrt{(X_i - \bar{X})^2 (Y_i - \bar{Y})^2}} \quad (1);$$

$$bias = \bar{Y} - \bar{X} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n}} \quad (3);$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |X_i - Y_i| \quad (4)$$

Onde \bar{X} e \bar{Y} são valores médios e X e Y são valores observados e estimados respectivamente, e n é o número de observações analisadas. R é a coeficiente de correlação; $RMSE$ é a raiz do erro quadrático médio; MAE é o erro médio absoluto e $bias$ é a diferença entre as médias estimadas e observadas respectivamente. Em outras palavras, $RMSE$ e MAE medem o desvio (sendo $RMSE$ mais suscetível às diferenças) e $bias$ indica se o modelo subestima ou superestima os valores observados (Xavier et al., 2022).

5. RESULTADOS

5.1 Simulação do clima presente

Um dos critérios comumente usados na avaliação de desempenho de qualquer modelo climático é se a condição histórica (observação) pode ser ou não replicada. Portanto torna-se indispensável que os dados oriundos das simulações de modelos para análises de qualquer temática sejam fiáveis, e que apresentem as mesmas propriedades dos dados meteorológicos observados, resultando em boa correlação entre ambos e que apresentem habilidade ótima em caracterizar a climatologia de um período de referência.

Os modelos do CMIP6 disponibilizam três categorias de simulações, entre elas a que analisar-se-á neste momento, que são relativas à experimentos históricos que cobrem todo o período que existem observações climáticas modernas. Esse período no CMIP6 é de 1850 a 2014. Esses dados servem para mostrar como os MCGs se comportam para o clima passado e poderão ser usados como comparação para cenários futuros. Nesse sentido, a primeira análise dessa pesquisa se dará para a comparação direta entre a precipitação acumulada extraída dos MCGs em relação à observação a fim de identificar a destreza dos mesmos na captura dos padrões comportamentais médios e suas nuances no NEB.

As Figuras 6 a 9 mostram, para cada estação do ano, a média climatológica do período 1961-2014 de cada MCG usado nessa pesquisa em relação à climatologia observada. A Figura 6 é para o período de verão, onde usou-se a média do trimestre dezembro-janeiro-fevereiro (DJF), trimestre tipicamente usado para representar o verão no hemisfério sul. A sequência da Figura 6 começa com a média observada (6a), seguida da média obtida diretamente dos modelos ACCESS-CM2 (6b), BCC-CSM2-MR (6c), CNRM-CM6-1-HR (6d), GFDL-ESM4 (6e), INM-CM5-0 (6f), MIROC6 (6g), NORESM2-MM (6h) e TaiESM1 (6i). A observação (dados interpolados) mostra precipitações acumuladas inferiores na faixa leste do NEB, variando de 50 mm a 300 mm, e superiores na faixa oeste, variando de 400 mm a 800 mm. Esse padrão é captado e apresentado nos MCGs, mas com erros evidentes. O ACCESS-CM2 (6b) mostra um

núcleo de precipitação no leste do NEB bem menos intenso que na observação, que se estende com valores mais baixos que a observação no norte do NEB. Todos os demais MCGs superestimam fortemente a precipitação acumulada no oeste do NEB, principalmente entre os estados do MA e PI, além de superestimar também o acumulado de chuvas da faixa leste.

O outono, mostrado na Figura 7, tem sua precipitação acumulada na faixa norte do NEB, devido principalmente a atuação da ZCIT, com valores inferiores de acumulação histórica no centro-sul do NEB, envolvendo por exemplo praticamente todo o estado da BA (Figura 7a). Os MCGs superestimam, sem exceção, a precipitação acumulada tanto no setor norte do NEB como em seu interior, com maior destaque para os MCGs ACCESS-CM2 (7b), BCC-SCM2 (7c), GFDL-ESM4 (7e), INM-CM5 (7f). Os MCGs MIROC6 (7g), NorESM2-MM (7h) e TaiESM1 (7i) são os que mais se aproximam do padrão observado nessa estação do ano, mesmo superestimando os valores. Já o CNRM-CM6 (7d), segue o padrão de superestimativa dos demais modelos, apesar de sua maior resolução original, aproximando-se mais da observação no setor do sudoeste baiano.

Para o inverno, trimestre junho-julho-agosto (JJA), a Figura 8 mostra que, com exceção do extremo leste do NEB que possui elevados índices de precipitação acumulada, podendo atingir até 800 mm entre PE e AL, e do extremo noroeste do MA que ainda pode atingir 600 mm de acumulação, o normal no interior do NEB são precipitação que atingem no máximo 50 mm nesse período, com valores um pouco mais elevados quanto mais aproxima-se da faixa litorânea. Esse padrão é captado com mais similaridade pelos modelos CNRM-CM6 (8D) E INM-CM5 (8F) para o leste do NEB, com a maior parte dos MCGs estendendo os limites mais secos do interior à faixa litorânea, caso do BCC-CSM2 (8c), GFDL-ESM4 (8e), MIROC6 (8g), NorESM2-MM (8h) e TaiESM1 (8i).

Por fim, para a primavera, trimestre setembro-outubro-novembro (SON), a Figura 9 exhibe padrão semelhante entre observação (9a) e simulações dos MCGs. Esse trimestre marca o retorno das chuvas no oeste da BA, e sul do MA e PI, contrastando com a época mais seca do ano no norte do NEB, entre CE, RN, PB, PE e centro-norte baiano. Alguns resultados peculiares dos MCGs merecem que se tome nota: a subestimativa da área seca no norte do NEB pelo BCC-CSM2 (9c), TaiESM1 (9i), CNRM-CM6 (9d) e INM-CM5 (9f), esses dois últimos citados, inclusive, superestimando a precipitação no leste do NEB e oeste do NEB, respectivamente.

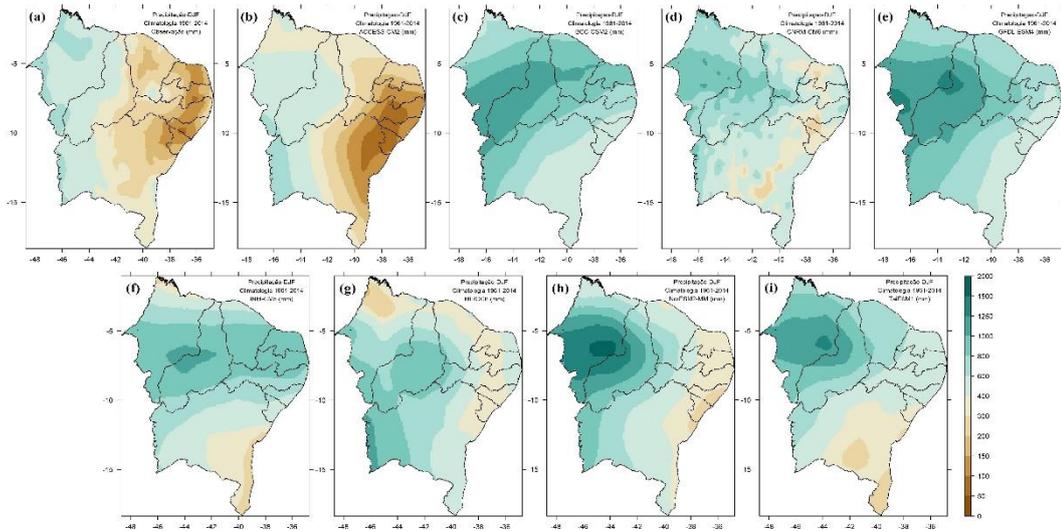


Figura 6. Climatologia da precipitação acumulada no verão (DJF), interpolada (a) e obtida dos modelos ACCESS-CM2 (b), BCC-CSM2-MR (c), CNRM-CM6-1-HR (d), GFDL-ESM4 (e), INM-CM5 (f), MIROC6 (g), NorESM2-MM (h) e TaiESM1 (i).

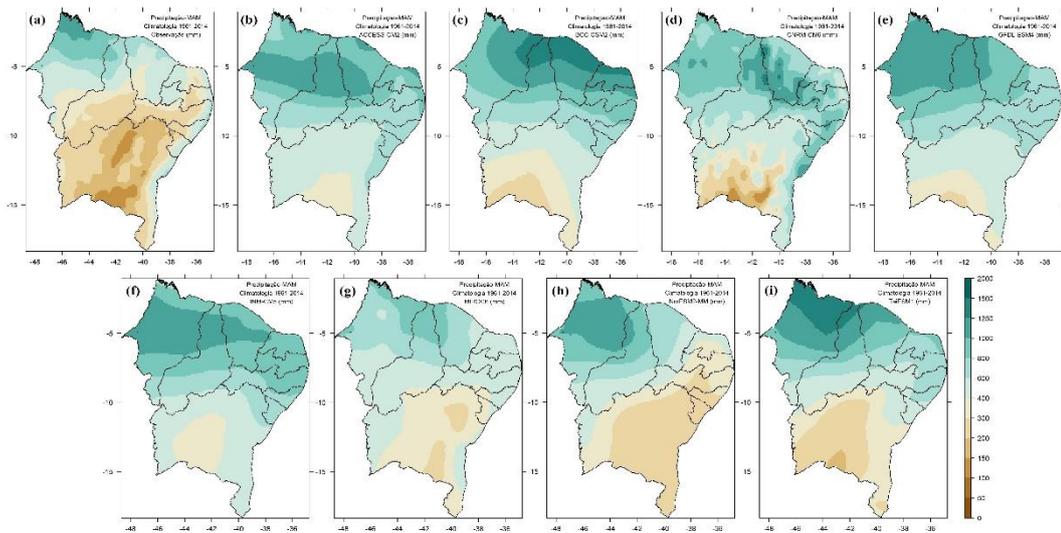


Figura 7. Climatologia da precipitação acumulada no outono (MAM), interpolada (a) e obtida dos modelos ACCESS-CM2 (b), BCC-CSM2-MR (c), CNRM-CM6-1-HR (d), GFDL-ESM4 (e), INM-CM5 (f), MIROC6 (g), NorESM2-MM (h) e TaiESM1 (i).

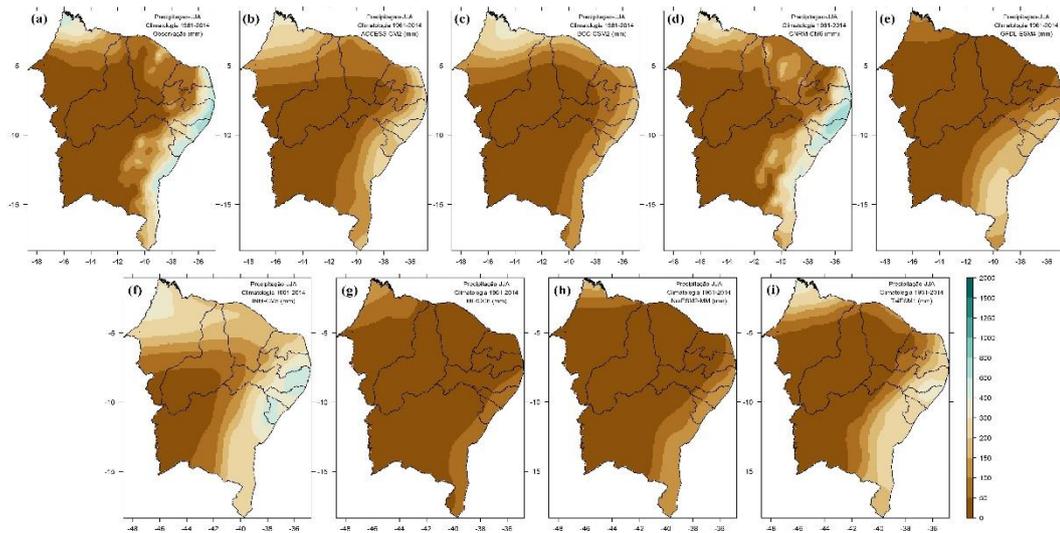


Figura 8. Climatologia da precipitação acumulada no inverno (JJA), interpolada (a) e obtida dos modelos ACCESS-CM2 (b), BCC-CSM2-MR (c), CNRM-CM6-1-HR (d), GFDL-ESM4 (e), INM-CM5 (f), MIROC6 (g), NorESM2-MM (h) e TaiESM1 (i).

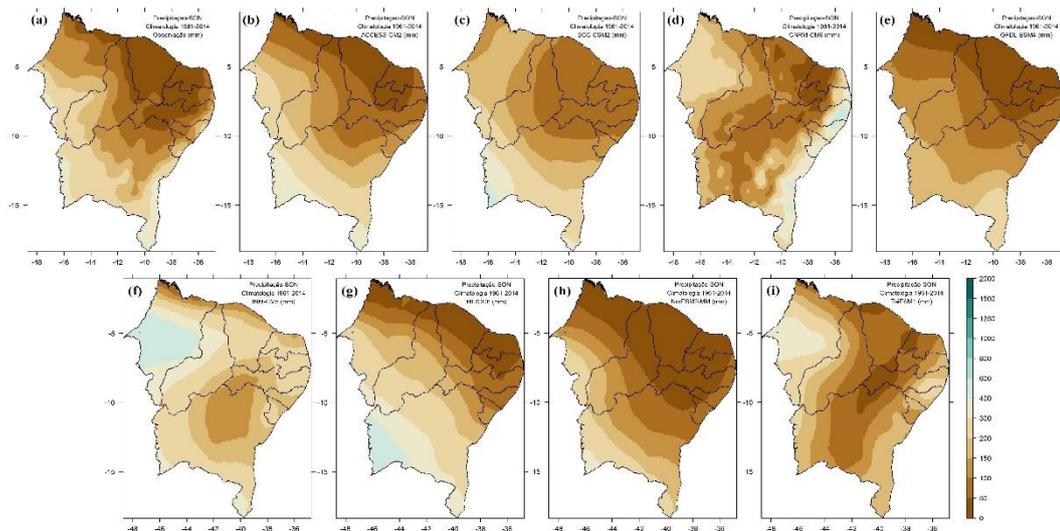


Figura 9. Climatologia da precipitação acumulada na primavera (MAM), interpolada (a) e obtida dos modelos ACCESS-CM2 (b), BCC-CSM2-MR (c), CNRM-CM6-1-HR (d), GFDL-ESM4 (e), INM-CM5 (f), MIROC6 (g), NorESM2-MM (h) e TaiESM1 (i).

5.2 Análise de erros dos MCGs para o clima presente

Para sintetizar a apresentação de tantas imagens, nessa seção serão exibidas figuras que mostram os resultados relativos a avaliação global de quatro parâmetros: o viés (bias), o erro médio absoluto (MAE), erro médio quadrático (RMSE) e correlação de Pearson (r), calculados em relação as observações do período 1961-2014.

A Figura 10 mostra o viés global dos MCGs. Esse resultado é obtido da média de todos os vieses obtidos mensalmente em todo o período de avaliação. Nota-se a tendência majoritária de superestimação da precipitação acumulada, principalmente na porção centro-norte do NEB,

com exceção dos modelos MIROC6 (10f) e NorESM2-MM (6g), cujos núcleos positivos estão um pouco mais deslocados até o oeste baiano e confinado no oeste do NEB entre MA e PI, respectivamente. São também nesses MCGs que se observa pequenos núcleos de valores negativos que indicam a tendência de subestimar a precipitação média acumulada mensal, no extremo noroeste maranhense e extremo leste do NEB, respectivamente. A maior parte dos modelos, com exceção do ACCESS-CM2 (10a) e MIROC6 (10f), apresenta vieses suaves, entre -10 a 10 mm, na maior parte da BA e no leste do NEB, com exceção do CNRM-CM6-1-HR (10c) nesse último setor citado. Nas áreas de superestimativa observada em todos os modelos, os valores situam-se normalmente entre 50 a 150 mm, podendo ultrapassar 200 mm em algumas áreas restritas. Esses valores, que representam um viés médio mensal, indica que as diferenças entre os totais anuais observados e simulados pelos modelos pode superar os 1000 mm em determinados anos.

Os resultados das Figuras 11 e 12, para MAE e RMSE, são complementares, uma vez que o RMSE é mais sensível aos erros do que o MAE. O MAE (Figura 11) mostra que para os modelos ACCESS-CM2 (11a), GFDL-ESM4 (11d), NorESM2-MM (11g) e TaiESM1 (11h), há uma área de erros maiores numa porção centro-oeste do NEB entre os estados do MA e PI, de até 175 mm, enquanto o BCC-CSM2-MR (11b) e INM-CM5-0 (11e) mostram uma área de maiores valores do MAE no nordeste do NEB entre CE, RN, PB e PE, com o CNRM-CM6-1-HR (11c) apresentando, em média, os menores erros. A magnitude desses erros é melhor observada justamente na Figura 12, com o RMSE, onde nota-se que as áreas com valores de MAE mais pronunciados atingem valores de até 200 mm a 300 mm, notando-se também que, em média, a área do NEB onde os MCGs erram menos e de forma relativamente concordante, é no centro-sul da BA.

Após a análise dos mapas de viés e dos erros, na Figura 13 apresenta-se a distribuição espacial das correlações globais (r) entre as séries contínuas de precipitação da observação versus cada MCG. Há um padrão muito similar entre os mapas, uma vez que observa-se valores baixos de r em toda a faixa leste do NEB, do RN ao sul da BA e envolvendo por completo alguns estados como AL e SE. Do contrário, há valores altos de correlações (estatisticamente significantes) em todas as áreas em tons de azul, com destaque para o oeste do NEB entre MA e PI com valores que superam 0,8, só que justamente onde observou-se os maiores valores de MAE e RMSE, podendo-se atribuir a essa combinação de altos valores de r e altos valores de erros a questão dessa área ser uma das mais chuvosas do NEB. Entre os modelos, os que apresentam valores de r um pouco menos baixos para o leste do NEB são o CNRM-CM6-1-HR

(13c), INM-CM5-0 (13e) e o TaiESM1 (13h), com valores majoritariamente entre 0 e 0,3, já os demais MCGs tem extensas áreas com correlações inclusive negativas.

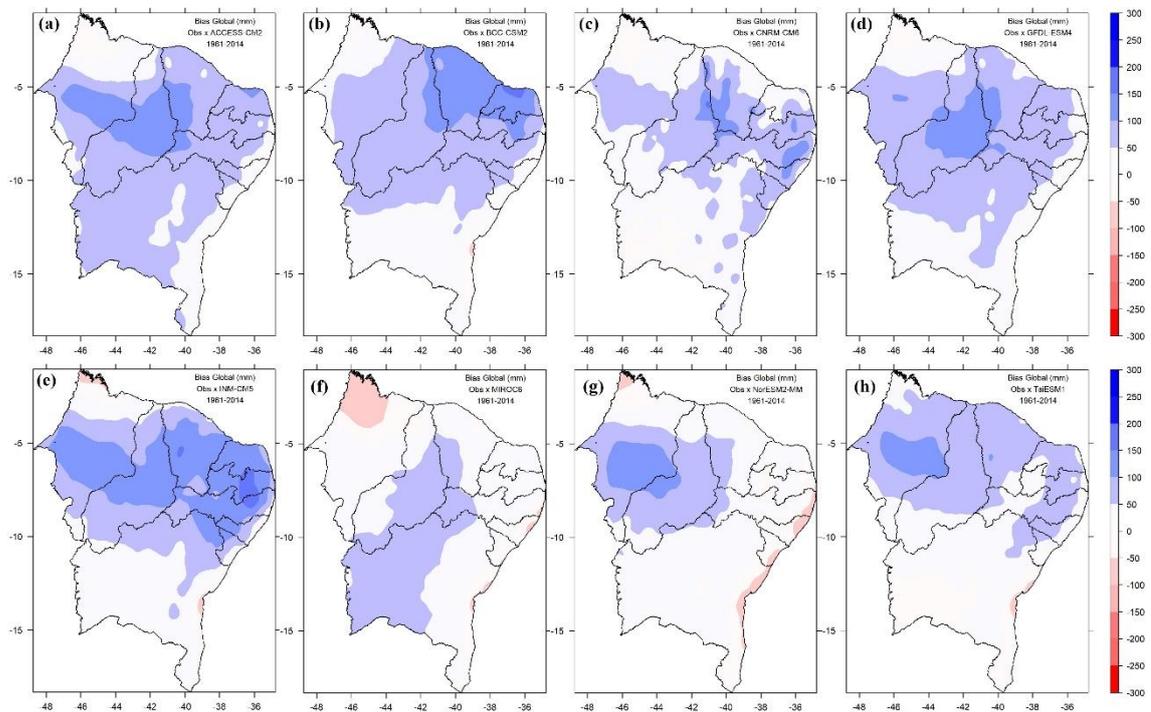


Figura 10. Viés global da precipitação média mensal dos MCGs em relação à interpolação para (a) ACCESS-CM2, (b) BCC-CSM2-MR, (c) CNRM-CM6-1-HR, (d) GFDL-ESM4, (e) INM-CM5, (f) MIROC6, (g) NorESM2-MM e (h) TaiESM1.

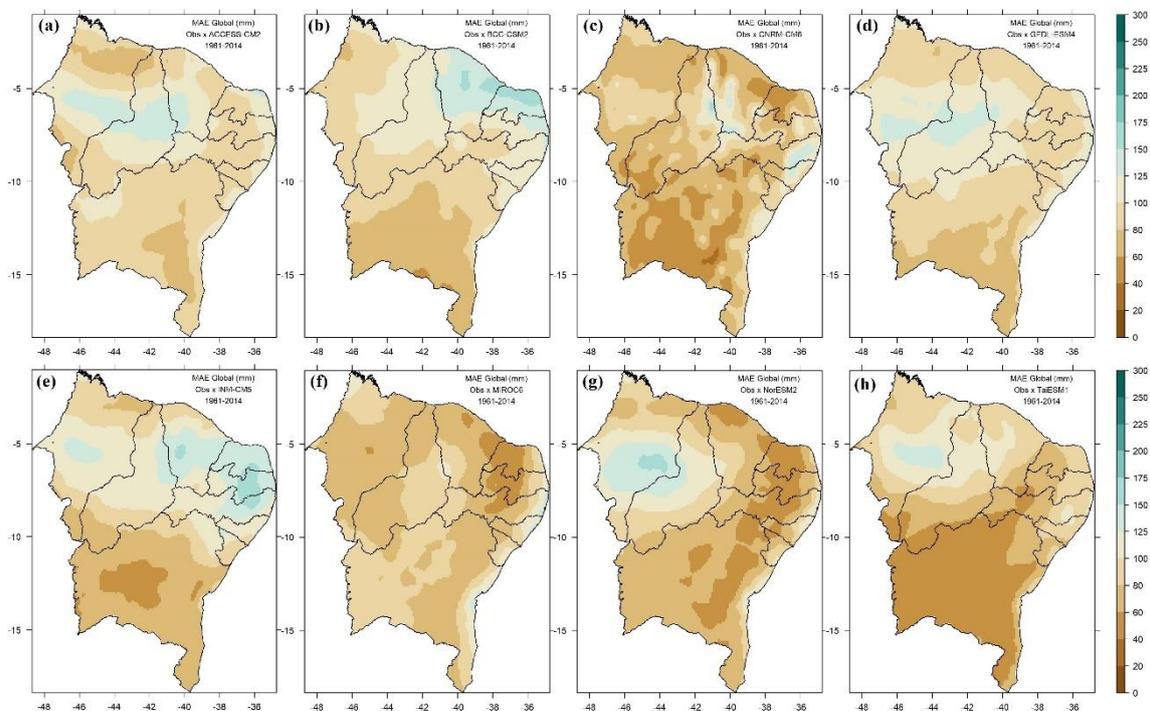


Figura 11. MAE da precipitação média mensal dos MCGs em relação à interpolação para (a) ACCESS-CM2, (b) BCC-CSM2-MR, (c) CNRM-CM6-1-HR, (d) GFDL-ESM4, (e) INM-CM5, (f) MIROC6, (g) NorESM2-MM e (h) TaiESM1.

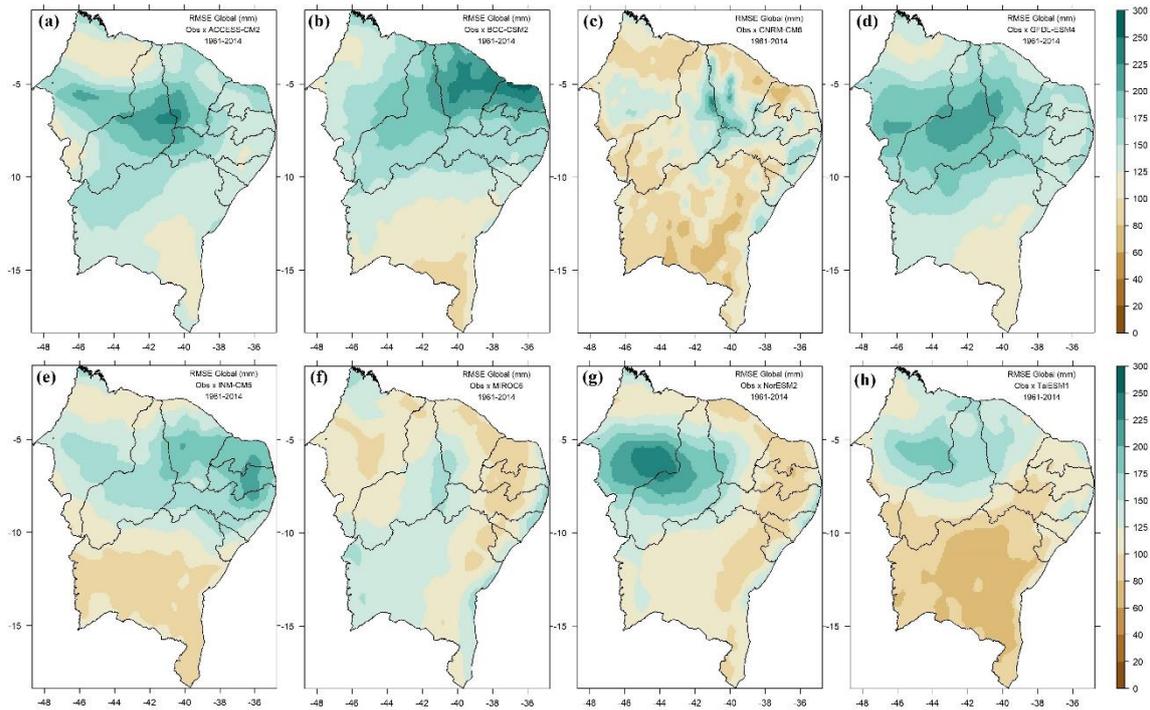


Figura 12. RMSE da precipitação média mensal dos MCGs em relação à interpolação para (a) ACCESS-CM2, (b) BCC-CSM2-MR, (c) CNRM-CM6-1-HR, (d) GFDL-ESM4, (e) INM-CM5, (f) MIROC6, (g) NorESM2-MM e (h) TaiESM1.

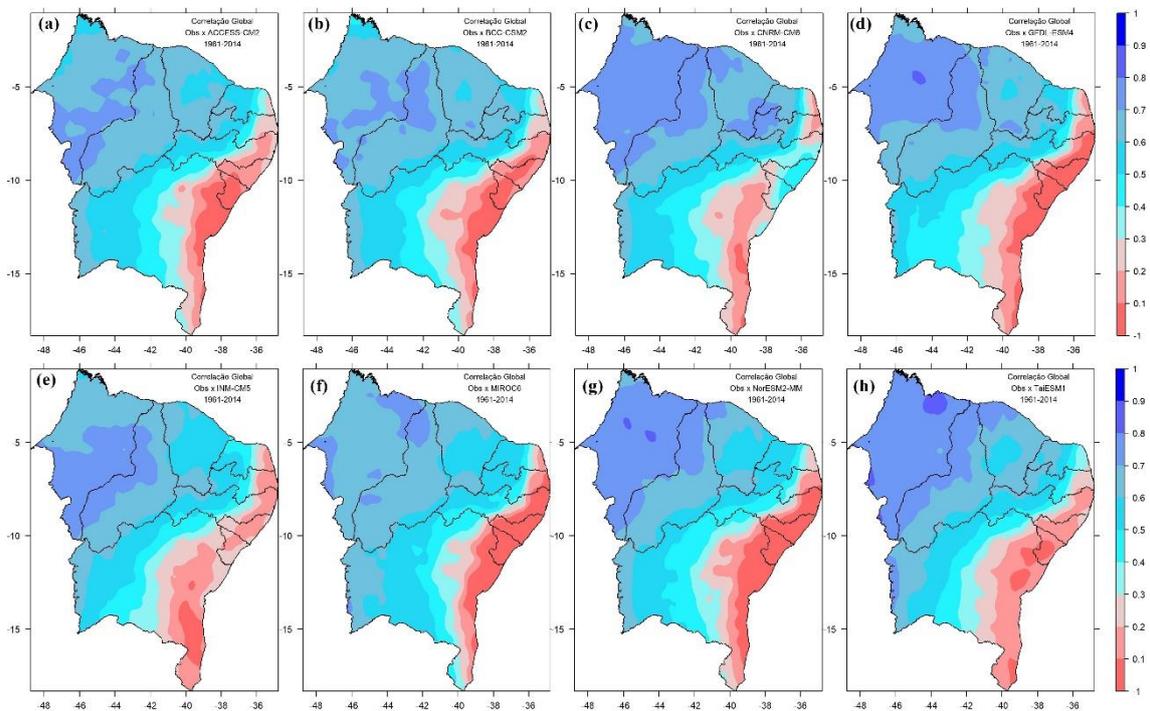


Figura 13. Correlação (r) da precipitação média mensal dos MCGs em relação à interpolação para (a) ACCESS-CM2, (b) BCC-CSM2-MR, (c) CNRM-CM6-1-HR, (d) GFDL-ESM4, (e) INM-CM5, (f) MIROC6, (g) NorESM2-MM e (h) TaiESM1.

5.3 Produtividade do milho, feijão e mandioca em Alagoas

Em Alagoas, como em boa parte do NEB, as culturas do feijão, milho e mandioca são cultivadas majoritariamente em regime de sequeiro, e para subsistência. De acordo com a Tabela 1, a produtividade média do feijão na mesorregião sertão é de 332 kg/ha, 416 kg/ha na mesorregião agreste e 456 kg/ha na mesorregião leste, de acordo com a Tabela 3. Esses valores são um indicativo de uma produtividade baixa, que emprega baixo ou nenhum nível tecnológico, quando comparados a valores médios observados em outras áreas do País que empregam mecanização e tecnologia na produção agrícola, haja visto que a produtividade média alcançada foi de 1.701 kg/ha na região Sudeste na safra 2018/2019 (Coelho e Ximenes, 2020). O mesmo acontece com a produtividade do milho, de apenas 370 kg/ha no sertão, 555 kg/ha no agreste e 543 kg/ha no leste, enquanto a produtividade média do milho no Brasil atingiu o valor de 4.366 kg/ha na safra 2020/2021, sendo comum produtores com médias acima de 10.000 kg/ha e até 12.000 kg/ha, chegando a patamares de 15.000 kg/ha (Contini et al., 2019).

A mandioca apresenta valores médios de produtividade de 8.531 kg/ha no sertão, 10.719 kg/ha no agreste e 10.055 kg/ha no leste, valores próximos aos rendimentos médios anuais da mandioca no NEB, que atualmente gira em torno de 10.000 kg/ha, valores inferiores no entanto aos obtidos em outras regiões, que já ultrapassaram 20.000 kg/ka como no caso do sul do Brasil. A mandioca é cultivada principalmente por pequenos produtores, que em razão do seu uso eficiente da água e dos nutrientes do solo, da tolerância à seca e a ataques esporádicos de pragas, fazem com que essa cultura apresente rendimentos razoáveis com utilização de pouco (ou nenhum) insumo, mesmo em locais com solos pobres e chuvas imprevisíveis (FAO, 2013).

Essas culturas, como já comentado, são basicamente cultivadas em regime de sequeiro, ou seja, dependem da disponibilidade natural e de uma boa distribuição espaço-temporal da precipitação, o que devido a variabilidade climática natural, traz aos produtores ao longo do tempo anos favoráveis e desfavoráveis à produção. As Figuras 14, 15 e 16 mostram, respectivamente, a distribuição anual da produtividade do feijão, milho e mandioca, respectivamente, em cada mesorregião, onde percebe-se essas variabilidades interanuais.

Tabela 3. Produtividade média do feijão, milho e mandioca nas mesorregiões de Alagoas no período de 1974-2014.

Mesorregião	Produtividade (kg/ha)		
	Feijão	Milho	Mandioca
Sertão	332	370	8531
Agreste	416	555	10719

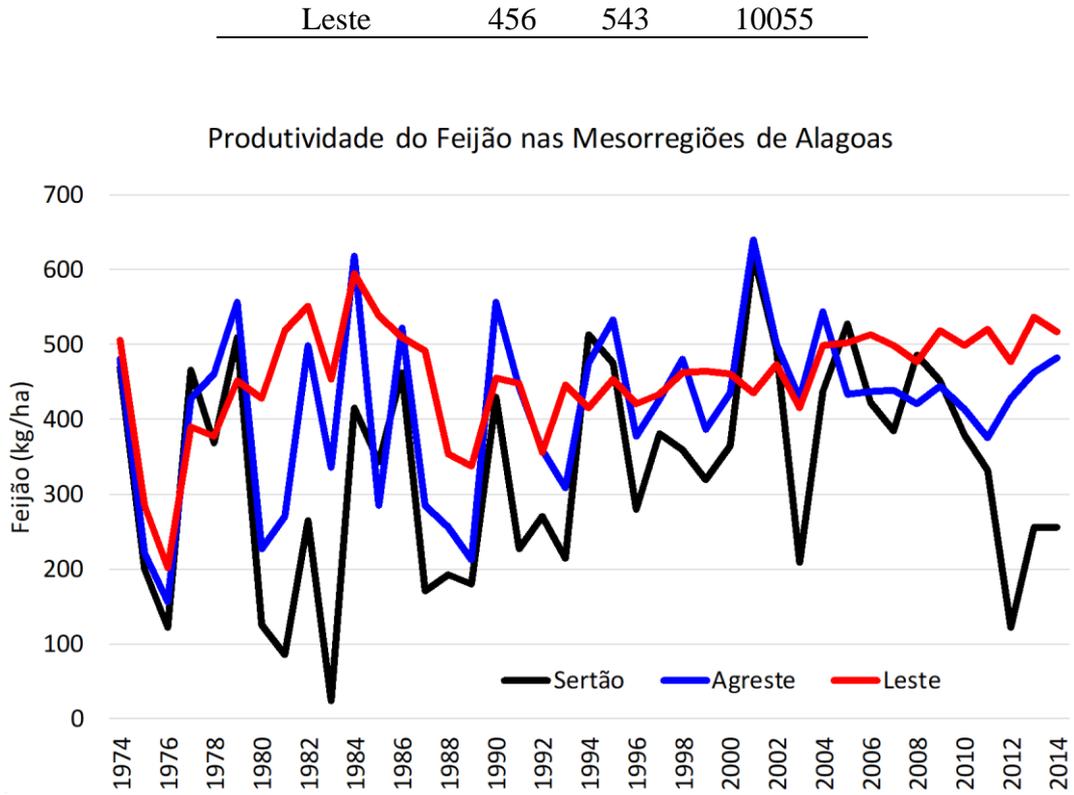


Figura 14. Variabilidade interanual da produtividade do feijão nas mesorregiões alagoanas.

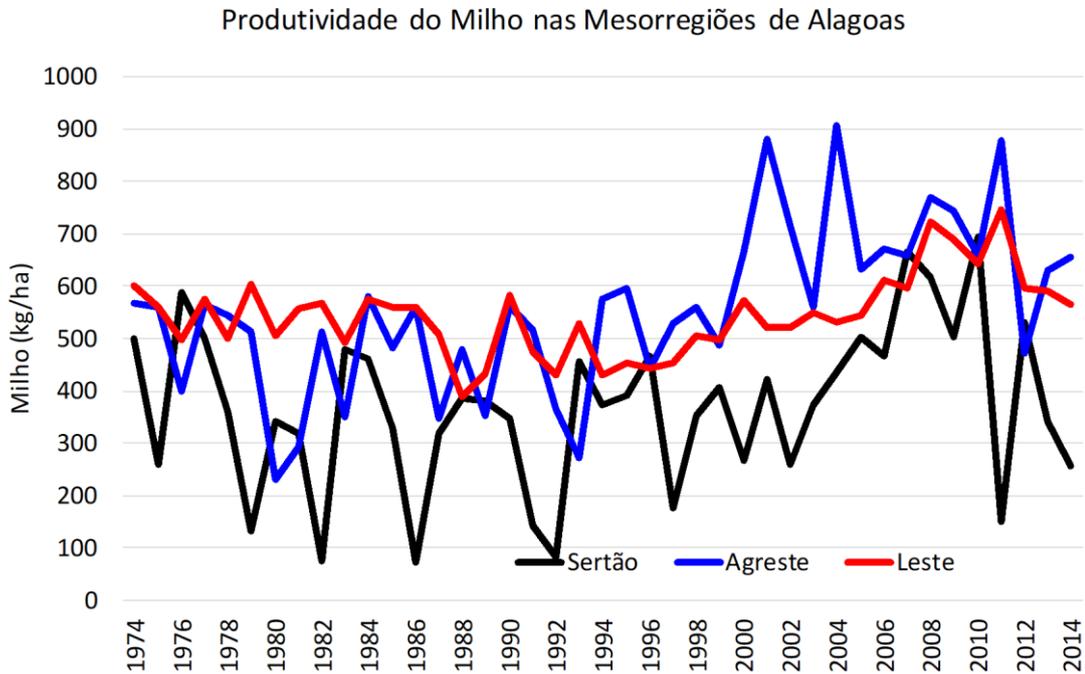


Figura 15. Variabilidade interanual da produtividade do milho nas mesorregiões alagoanas.

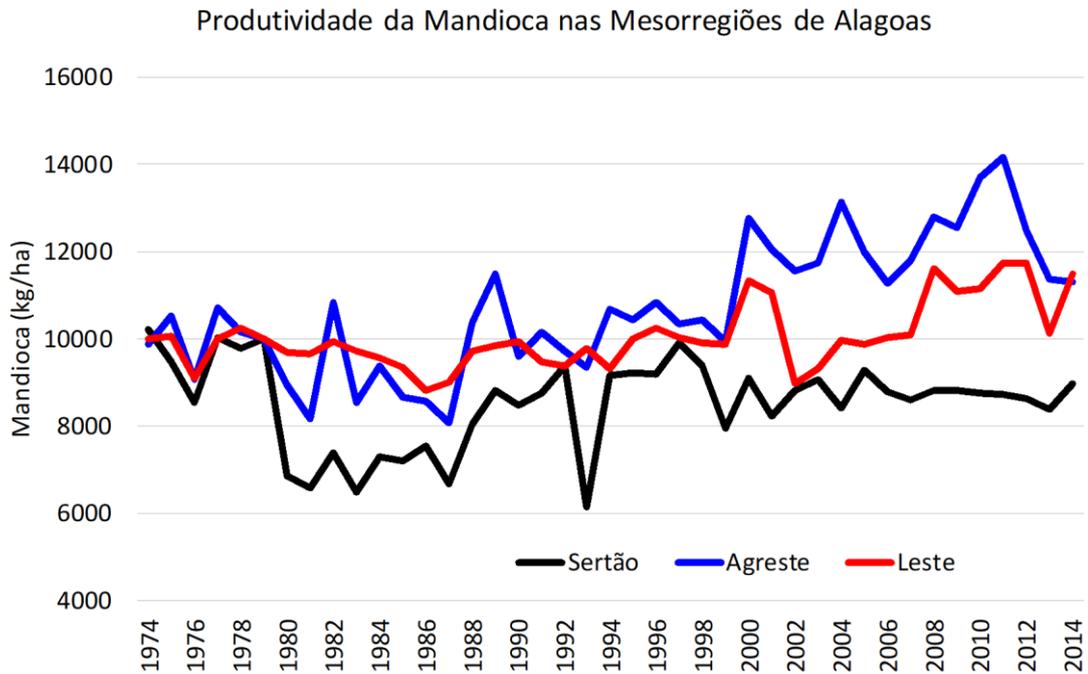


Figura 16. Variabilidade interanual da produtividade da mandioca nas mesorregiões alagoanas.

5.4 Avaliação da correção de viés dos modelos do CMIP6 com ACC

Os resultados apresentados no tópico 5.1 mostraram que os modelos do CMIP6 diferem significativamente das observações, em média, para a precipitação acumulada. A fim de sintetizar a apresentação dos resultados referentes a correção do viés dessa precipitação, introduz-se nessa seção o conceito de *ensemble*. Esse termo em inglês refere-se a média de um conjunto, em nosso caso, será a média do conjunto de 8 modelos do CMIP6 tratados aqui nessa pesquisa. Isso reduz a quantidade de figuras e gráficos que seriam mostrados para cada modelo, sem diminuir por isso a eficácia da análise.

As Figuras 17 e 18 mostram, por exemplo, a comparação entre a climatologia da precipitação acumulada de cada semestre do ano a partir dos dados observados, do *ensemble* dos modelos e desse mesmo *ensemble* após a correção de viés com ACC. Na Figura 17a, para o primeiro semestre do ano no NEB, percebe-se da média observada o noroeste mais chuvoso entre Ceará, oeste do Piauí e todo estado do Maranhão, assim como a faixa leste mais chuvosa do NEB, com precipitação acumulada que pode ultrapassar 1500 mm, e o interior semiárido mais seco com núcleos de precipitação acumulada inferiores a 300 mm. De forma contrastante, a média climatológica para o primeiro semestre obtida de todos os modelos demonstra forte superestimativa da precipitação acumulada (Figura 17b). Após a correção de viés com ACC (Figura 17c), embora o período climatológico seja diferente do das observações, nota-se extrema semelhança entre a climatologia obtida do *ensemble* dos modelos com a obtida de observações no período 1961-2014 (Figura 17a). Resultados semelhantes aos do primeiro

semestre são mostrados na Figura 18 para a climatologia da precipitação acumulada do segundo semestre do ano e na Figura 19 para a média de chuvas acumuladas anuais no NEB. Tais resultados corroboram que a técnica de ACC foi eficiente em reduzir os desvios dos modelos em relação as observações.

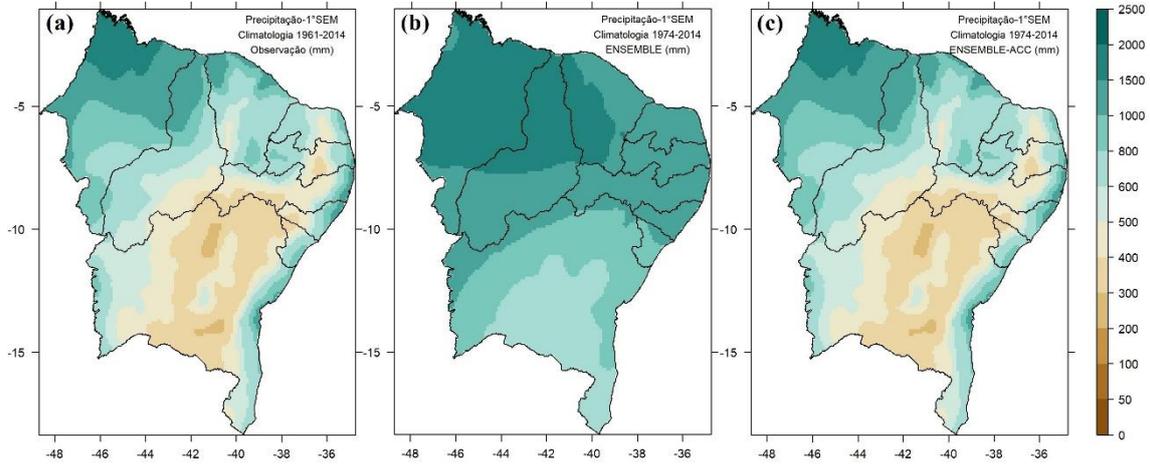


Figura 17. Primeiro semestre do ano: (a) Climatologia da precipitação acumulada interpolada no período 1961-2014, (b) obtida a partir do *ensemble* de modelos do CMIP6 para 1974-2014, e (c) obtida a partir obtida do *ensemble* de modelos do CMIP6 para 1974-2014 após correção com ACC.

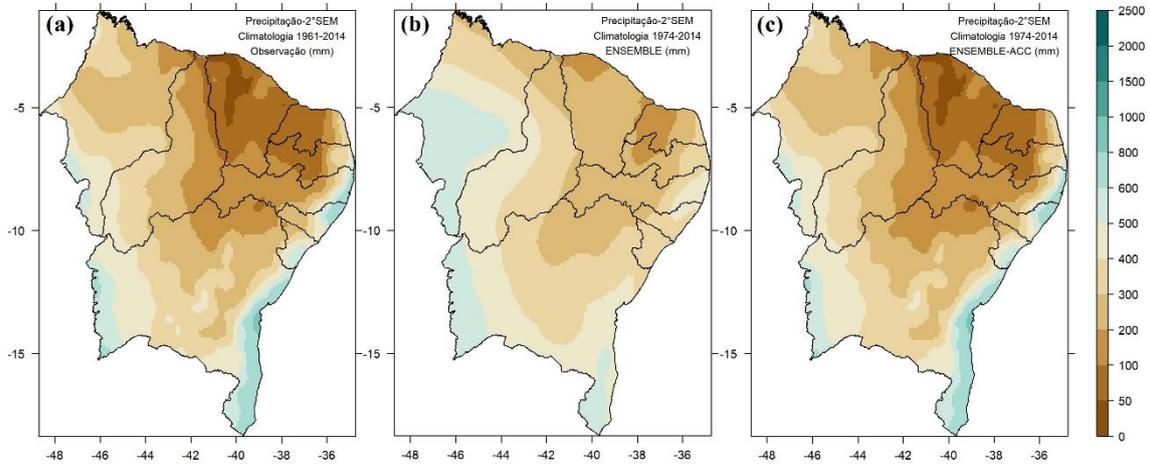


Figura 18. Segundo semestre do ano: (a) Climatologia da precipitação acumulada interpolada no período 1961-2014, (b) obtida a partir do *ensemble* de modelos do CMIP6 para 1974-2014, e (c) obtida a partir obtida do *ensemble* de modelos do CMIP6 para 1974-2014 após correção com ACC.

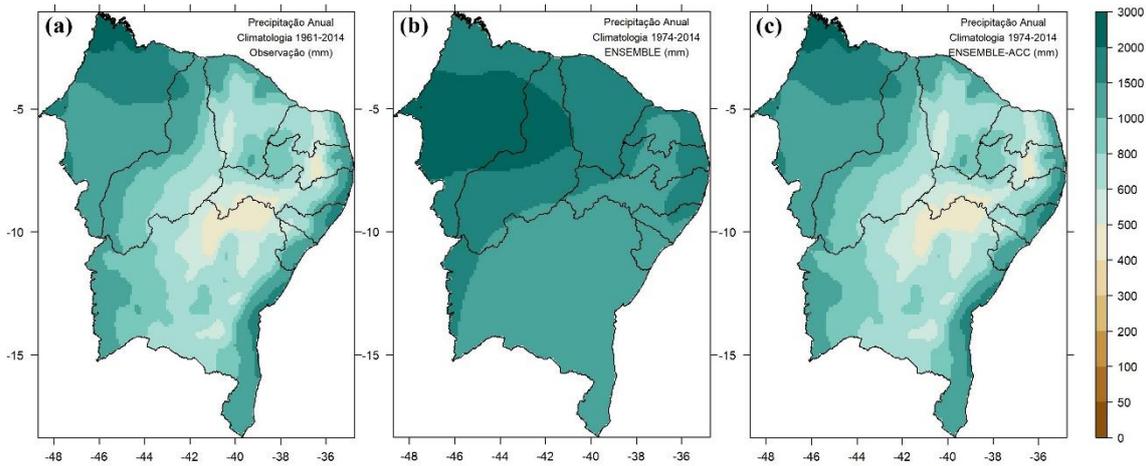


Figura 19. A cumulada médio anual de precipitação no NEB: (a) Climatologia da precipitação acumulada interpolada no período 1961-2014, (b) obtida a partir do *ensemble* de modelos do CMIP6 para 1974-2014, e (c) obtida a partir obtida do *ensemble* de modelos do CMIP6 para 1974-2014 após correção com ACC.

Esses resultados climatológicos que evidenciam a habilidade da técnica de ACC na correção do viés da precipitação média acumulada no NEB é destacada pelas métricas estatísticas usadas nessa pesquisa, sendo elas o viés, a correlação, o MAE e o RMSE. A Figura 20 mostra o viés global representado pela média da precipitação total do período 1971-2014 obtida diretamente do ensemble dos modelos originais do CMIP6 e após o pós-processamento com ACC. A superestimação dos modelos do CMIP6 é demonstrada mais claramente no mapa do viés da Figura 20a, entre 50 a 150 mm em média em boa parte do centro-norte do NEB, com pequenas áreas de subestimação no extremo noroeste do Maranhão e em partes da faixa leste do NEB, que chegam a ser inferiores a 50 mm. Após a correção desse viés com ACC (Figura 20b), nota-se a clara diminuição da magnitude do viés, reduzindo-se a valores que não chegam a ultrapassar 50 mm para mais ou para menos em núcleos dispersos por toda a área do NEB.

A Figura 21 demonstra que os modelos do CMIP6 apresentam forte não linearidade para a precipitação estimada mês a mês no leste do NEB. A média de todos os modelos (Figura 21a) mostra as baixas correlações nessa porção do NEB que, em determinados casos devido a extensão territorial dos estados, como Alagoas e Sergipe, representa que nenhuma área possui correlação estatisticamente significativa, refletida nas figuras por áreas com correlação inferior a 0,3, cujo p-valor é superior a 0,05 para um intervalo de confiança de 95% relativo ao teste *t-student* empregado para avaliar a significância desse parâmetro estatístico. Com a média dos modelos após o uso da ACC para correção dos vieses sistemáticos dos modelos, a correlação é aumentada e estatisticamente significante em toda a área do NEB, mesmo nas porções do leste da Bahia onde os menores valores são encontrados, mas superiores ao limiar crítico de significância que é de uma correlação maior ou igual a 0,31. Percebe-se, antes e após a

calibração da precipitação dos modelos com ACC, que há um perceptível gradiente leste-oeste nos valores das correlações (efeito diminuído após a correção com ACC), com as maiores correlações sendo observadas nos estados do norte do NEB, desde Rio Grande do Norte até o Maranhão, até o oeste da Bahia. Esse resultado evidencia a dificuldade de modelos do CMIP6 em estimar corretamente o sinal das precipitações acumuladas na faixa leste do NEB.

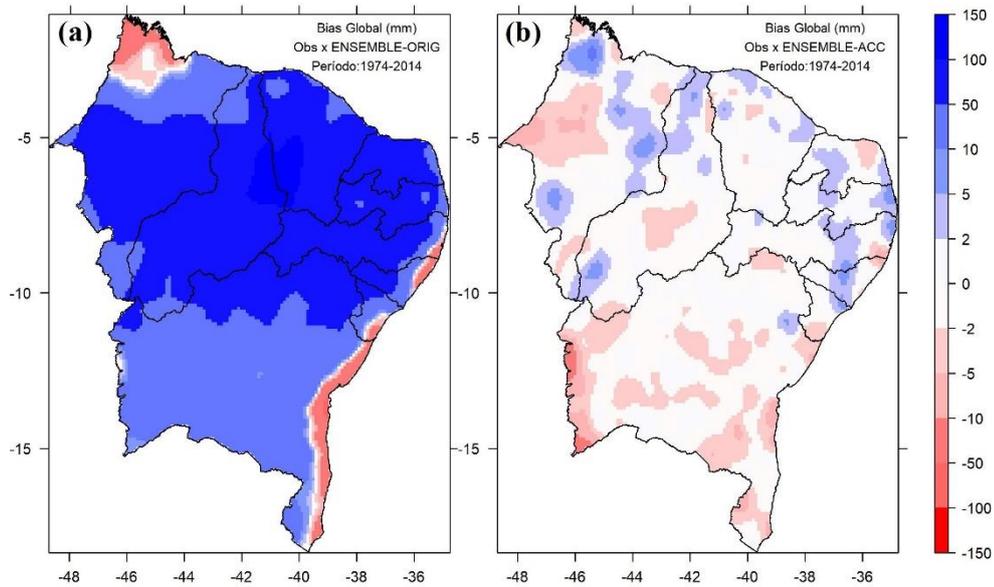


Figura 20. Viés global da precipitação, em mm, do *ensemble* dos modelos em relação à observação antes da calibração com ACC (a), e após a calibração com ACC (b).

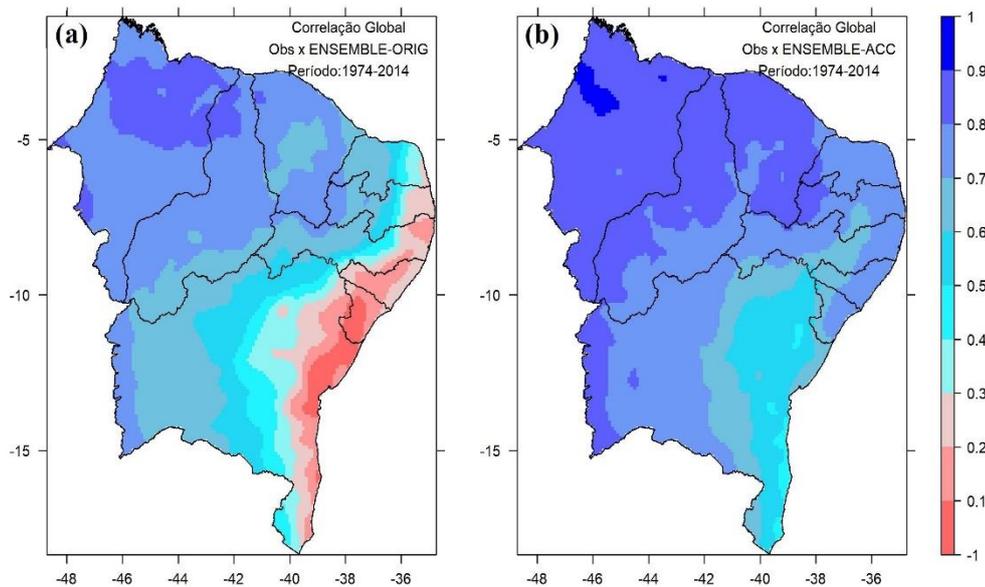


Figura 21. Correlação (r) da precipitação, em mm, do *ensemble* dos modelos em relação à observação antes da calibração com ACC (a), e após a calibração com ACC (b).

Em relação as medidas de erros dos modelos, tanto o MAE quanto o RMSE foram significativamente diminuídos após a calibração com ACC (Figuras 22b e 23c) em relação à média dos dados originais sem qualquer tipo de correção (Figuras 22a e 23a). As áreas com os erros mais significativos, situados em uma área contínua abrangendo Maranhão, Piauí, Ceará e oeste de Pernambuco, foi sensivelmente reduzida. Esses resultados finalizam o primeiro grande objetivo dessa pesquisa, que era atestar se a técnica de ACC seria capaz de aproximar a precipitação acumulada simulada pelos modelos com as das observações.

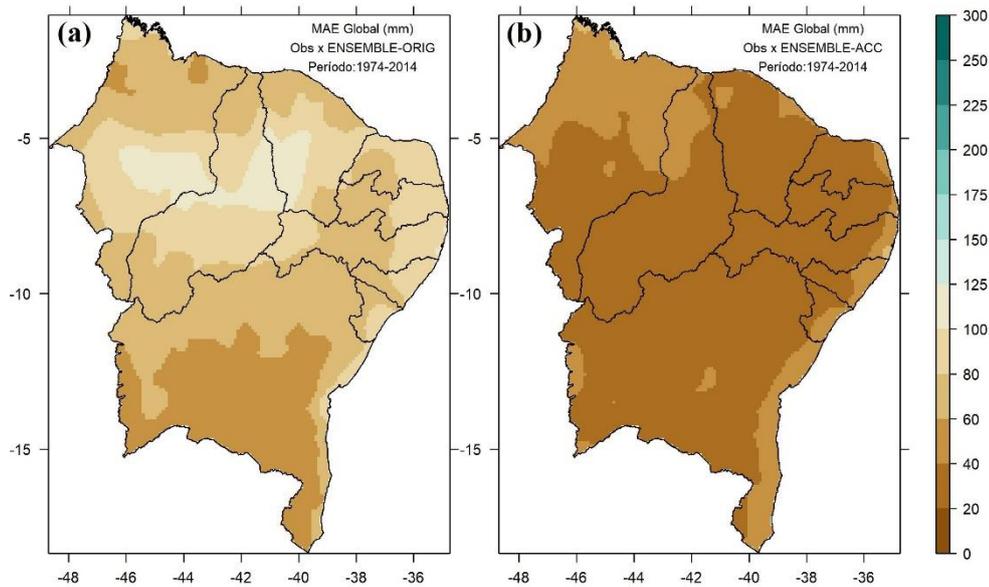


Figura 22. MAE da precipitação, em mm, do *ensemble* dos modelos em relação à observação antes da calibração com ACC (a), e após a calibração com ACC (b).

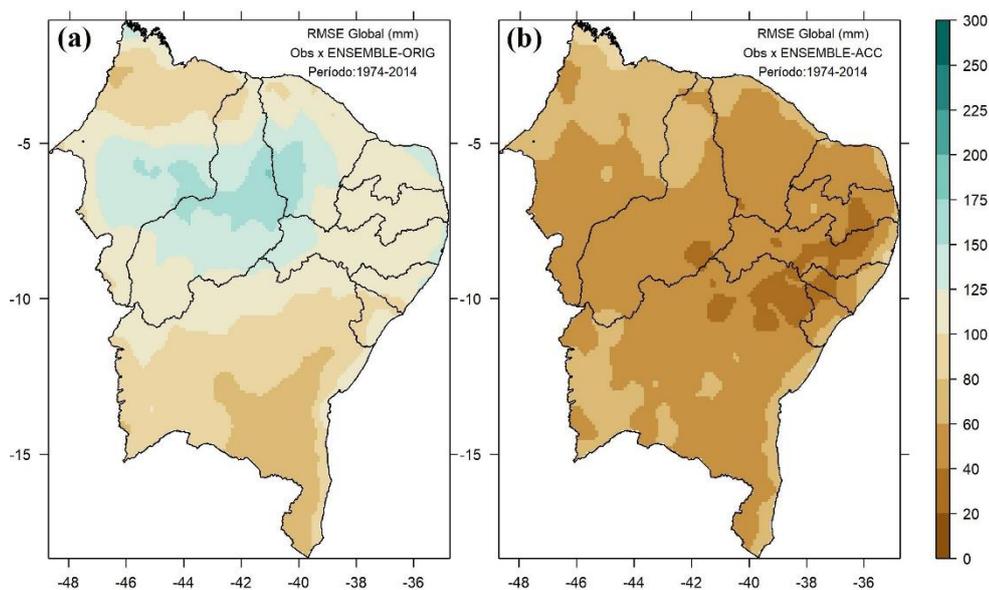


Figura 23. RMSE da precipitação, em mm, do *ensemble* dos modelos em relação à observação antes da calibração com ACC (a), e após a calibração com ACC (b).

5.5 Simulação da produção das culturas a partir da precipitação observada e estimada pelos modelos do CMIP6.

Os resultados apresentados no tópico 5.4 mostraram que os modelos do CMIP6 podem ter sua precipitação original estimada amplamente melhorada se alguma técnica de pós processamento dessas informações for adotada. A ACC mostrou-se uma metodologia eficaz para a reamostragem da precipitação dos modelos do CMIP6 no período histórico de 1974 a 2014. Diante disso, a etapa seguinte consiste em analisar o potencial da previsão das principais safras de Alagoas - feijão, milho e mandioca - considerando as três mesorregiões do estado. Esta avaliação será conduzida a partir da precipitação interpolada e nas projeções dos modelos, antes e após calibração com ACC, durante a principal estação de crescimento dessas culturas, que ocorre entre os meses de abril a setembro.

A ACC é uma técnica de análise multivariada amplamente utilizada para gerar previsões climáticas operacionais (Mason e Tippett., 2017; Esquivel et al., 2018; Hossain et al., 2019), mas que também pode ser usada para relacionar saídas brutas de modelos dinâmicos à observações, por exemplo, precipitação acumulada prevista de um mês relativo a um período de referência passado (hindcast) com as observações reais desse período, e assim recalibrar e corrigir vieses nessas previsões, permitindo aplicar essa correção as futuras previsões dos modelos.

Totais de precipitação do semestre AMJJAS foram os preditores (X), e a produção média do feijão, milho e mandioca de cada mesorregião de Alagoas os preditandos (Y). Ambos os campos são pré-filtrados com Funções Ortogonais Empíricas (FOE) para eliminar ruídos dos dados originais (Horel, 1981). Nesse processo, as FOE de X e Y são calculadas separadamente, estabelecendo-se um modelo que retenha em torno de 70% a 80% da variância original de cada variável a partir de um número de autovetores. Esse processo força a ACC a enfatizar os modos de variabilidade dominantes de X e Y. Em seguida, uma matriz de correlação cruzada é construída com as séries das componentes principais de X e Y, que tem suas dimensões reduzidas ao número de modos retidos pelo preditor e pelo preditando, obtendo-se autovetores e autovalores canônicos para X e Y dessa matriz transposta.

Encontra-se a função canônica do preditor a partir das combinações lineares entre os autovetores canônicos e as séries das componentes principais do preditor para cada modo. A equação de regressão expressa pelos modos canônicos deriva das variáveis originais, convertendo-se a função temporal canônica do preditor em função temporal canônica do preditando. Por fim, a equação preditiva é obtida para relacionar preditor ao preditando, ou X a Y, e as simulações históricas e/ou previsões, podem ser realizadas. Essa pesquisa se ateve a

simulações históricas, recomendando-se para pesquisas subsequentes usar os modelos para estimar a produção futura dessas culturas mediante cenários de mudanças climáticas.

A Tabela 4 mostra os parâmetros obtidos a partir do uso da precipitação interpolada acumulada de abril a setembro como variável preditora da produção das culturas de 1974 a 2014. Os resultados mostram, para todas as culturas nas três mesorregiões, valores de correlação estatisticamente significativas, e respectivos valores de erros. As Tabelas 5 e 6 mostram os mesmos parâmetros obtidos a partir da simulação da produção das culturas com a precipitação do modelo australiano ACCESS-CM2 antes e após a calibração com ACC.

Tabela 4. Parâmetros estatísticos obtidos a partir da simulação da produção das culturas nas mesorregiões alagoanas usando como variável preditora a precipitação interpolada no semestre AMJJAS. Valores de correlação em azul destacam a significância estatística.

Simulação a partir da precipitação observada				
Culturas	CORREL	BIAS	MAE	RMSE
Feijão-sertão	0,66	0,0	87	105
Mandioca-sertão	0,66	0,0	608	763
Milho-sertão	0,84	0,0	72	83
Feijão-agreste	0,49	0,0	80	97
Mandioca-agreste	0,84	0,0	668	802
Milho-agreste	0,77	0,0	78	100
Feijão-leste	0,53	0,0	45	63
Mandioca-leste	0,70	0,0	412	536
Milho-leste	0,71	0,0	42	54

Tabela 5. Parâmetros estatísticos obtidos a partir da simulação da produção das culturas nas mesorregiões alagoanas usando como variável preditora a precipitação original do modelo ACCESS-CM2. Valores de correlação em azul destacam a significância estatística.

Simulação a partir da precipitação ACCESS-CM2 sem ACC				
Culturas	CORREL	BIAS	MAE	RMSE
Feijão-sertão	0,38	0,0	106	130
Mandioca-sertão	0,16	0,0	801	1002
Milho-sertão	0,35	0,0	114	144
Feijão-agreste	0,34	0,0	81	104
Mandioca-agreste	0,17	0,0	1167	1472
Milho-agreste	0,38	0,0	115	144
Feijão-leste	0,17	0,0	54	73
Mandioca-leste	0,17	0,0	534	744
Milho-leste	0,10	0,0	57	76

Tabela 6. Parâmetros estatísticos obtidos a partir da simulação da produção das culturas nas mesorregiões alagoanas usando como variável preditora a precipitação do modelo ACCESS-CM2 após correção do viés com ACC. Valores de correlação em azul destacam a significância estatística.

Simulação a partir da precipitação ACCESS-CM2 com ACC				
Culturas	CORREL	BIAS	MAE	RMSE
Feijão-sertão	0,55	0,0	104	120
Mandioca-sertão	0,39	0,0	737	946
Milho-sertão	0,48	0,0	113	135
Feijão-agreste	0,43	0,0	76	100
Mandioca-agreste	0,45	0,0	1058	1333
Milho-agreste	0,57	0,0	92	129
Feijão-leste	0,18	0,0	54	73
Mandioca-leste	0,31	0,0	539	720
Milho-leste	0,43	0,0	53	69

Diante dos resultados apresentados nas tabelas 4, 5 e 6, nota-se que seria repetitivo apresentar todas as tabelas para os demais sete modelos restantes. Dessa forma, a fim de sintetizar os resultados dos modelos individualmente, mostra-se na Tabela 7 o número de mesorregiões com culturas cujas simulações apresentaram correlações estatisticamente significativas. Vê-se na Tabela que, com exceção dos modelos GFDL-ESM4 e NORESM2-MM, que apresentaram correlações significativas para todas as culturas em todas as mesorregiões, em média as simulações com a precipitação dos modelos após calibração com ACC apresenta número maior de mesorregiões com correlações estatisticamente significantes. As medidas de erro das estimativas em relação a média das observações, MAE e RMSE, naturalmente aumentam com as simulações dos modelos antes e após correção do viés com ACC em relação as simulações usando a precipitação observada do período, o que é natural ao se tratar de modelagem numérica. No entanto, tais erros são geralmente, inferiores ao valor do desvio padrão observado.

No entanto, os resultados da Tabela 7 não mostram, em média, um número muito mais elevado de simulações para as culturas em suas mesorregiões com correlações estatisticamente significantes em relação as simulações com as precipitações originais dos modelos sem nenhum tipo de tratamento. Isso demonstra que a técnica em si de previsão usando ACC, independentemente de haver ou não a correção da precipitação bruta dos modelos, tem a tendência de tentar ajustar o máximo possível um modelo de regressão que seja condizente entre a variável preditora (precipitação calibrada ou não) e o preditando (a produção das culturas nas mesorregiões alagoanas).

Tabela 7. Número de simulações, de acordo com as mesorregiões, que apresentaram correlações significativas da produção quando comparadas a produção observada.

Mesorregiões com simulações estatisticamente significativas			
Modelo	$r \geq 0,3$ antes da correção com ACC	$r \geq 0,3$ após da correção com ACC	
ACCESS-CM2	4	8	
BCC-CSM2-MR	6	8	
CNRM-CM6-1-HR	6	7	
GFDL-ESM4	9	8	
MIROC6	7	9	
NORESM2-MM	6	5	
INM-CM5-0	9	6	
TaiESM1	8	9	
Média	7	8	

Os resultados sintetizados da Tabela 7 motivaram a investigação final dessa pesquisa, que foi avaliar esses mesmos parâmetros, quando obtidos de simulações a partir do *ensemble* da precipitação original, e após calibração com ACC, dos oito modelos do CMIP6. Por fim, esses resultados são comparados aos resultados do ensemble da própria produção simulada pelos modelos. De forma relativamente surpreendente, ao se usar como variável preditora a precipitação original média dos modelos sem calibração com ACC, o resultado das simulações da produção das culturas é um pouco superior aos mesmos resultados obtidos com a variável preditora sendo a precipitação média dos modelos calibrados com ACC. Isso pode ser visto nas Tabelas 8 e 9, respectivamente. Na Tabela 8 percebe-se que 8 das 9 simulações usando-se a precipitação dos modelos sem correção apresentaram correlações estatisticamente significativas, contra 7 das 9 simulações usando-se a precipitação dos modelos com correção de viés.

Tabela 8. Parâmetros estatísticos obtidos a partir da simulação da produção das culturas nas mesorregiões alagoanas usando como variável preditora a precipitação média dos modelos no semestre AMJJAS sem correção de viés da ACC. Valores de correlação em azul destacam a significância estatística.

Simulação a partir do ensemble da precipitação dos modelos sem ACC				
Culturas	CORREL	BIAS	MAE	RMSE
Feijão-sertão	0,54	0,0	97	119
Mandioca-sertão	0,34	0,0	764	958
Milho-sertão	0,35	0,0	114	143
Feijão-agreste	0,59	0,0	76	90
Mandioca-agreste	0,31	0,0	1093	1426
Milho-agreste	0,42	0,0	101	142

Feijão-leste	0,19	0,0	55	73
Mandioca-leste	0,38	0,0	546	698
Milho-leste	0,36	0,0	54	71

Tabela 9. Parâmetros estatísticos obtidos a partir da simulação da produção das culturas nas mesorregiões alagoanas usando como variável preditora a precipitação média dos modelos no semestre AMJJAS com correção de viés da ACC. Valores de correlação em azul destacam a significância estatística.

Simulação a partir do ensemble da precipitação dos modelos com ACC				
Culturas	CORREL	BIAS	MAE	RMSE
Feijão-sertão	0,53	0,0	102	121
Mandioca-sertão	0,33	0,0	741	962
Milho-sertão	0,51	0,0	108	133
Feijão-agreste	0,31	0,0	81	105
Mandioca-agreste	0,62	0,0	964	1203
Milho-agreste	0,57	0,0	95	128
Feijão-leste	0,13	0,0	55	74
Mandioca-leste	0,36	0,0	526	703
Milho-leste	0,29	0,0	57	73

Diante dos resultados apresentados, e com a justificativa de se avaliar se os mesmos parâmetros estatísticos seriam similares aos das Tabelas 8 e 9 usando-se, de forma mais simples, a média das próprias simulações dos modelos antes e após a calibração com ACC, chega-se ao resultado mais interessante da pesquisa. Uma vez findadas as simulações com cada modelo, para cada cultura de respectiva mesorregião, usando-se como variáveis preditoras a precipitação acumulada dos modelos sem e com correção de viés, tem-se que, tanto para as situações envolvendo ou não o pós-processamento da precipitação com ACC, os parâmetros são os melhores encontrados e as simulações tendem, em média, a representarem melhor o comportamento observado.

Da média das simulações sem calibração da precipitação dos modelos, a menor correlação entre simulação da produção com as observações foi de 0,74 para o milho da mesorregião leste de Alagoas, e a maior de 0,85 para o feijão da mesorregião do sertão alagoano. Já da média de simulações da produção proveniente dos modelos com calibração da precipitação, a menor correlação foi de 0,64 para a mandioca do leste alagoano e a maior foi de 0,79 para o feijão do sertão alagoano. Esses resultados são apresentados nas Tabelas 10 e 11, respectivamente.

Tabela 10. Parâmetros estatísticos obtidos a partir da média das simulações da produção das culturas nas mesorregiões alagoanas usando como variável preditora a precipitação média dos modelos no semestre AMJJAS sem correção de viés da ACC. Valores de correlação em azul destacam a significância estatística.

Simulação a partir do ensemble das produções obtidas sem calibração da precipitação dos modelos com ACC				
Culturas	CORREL	BIAS	MAE	RMSE
Feijão-sertão	0,79	0,0	99	118
Mandioca-sertão	0,75	0,0	693	870
Milho-sertão	0,85	0,0	94	119
Feijão-agreste	0,82	0,0	73	91
Mandioca-agreste	0,77	0,0	1042	1238
Milho-agreste	0,80	0,0	98	127
Feijão-leste	0,80	0,0	47	62
Mandioca-leste	0,82	0,0	453	607
Milho-leste	0,74	0,0	49	62

Tabela 11. Parâmetros estatísticos obtidos a partir da média das simulações oriundas dos modelos calibrados, no semestre AMJJAS. Valores de correlação em azul destacam a significância estatística.

Simulação a partir do ensemble das produções obtidas com calibração da precipitação dos modelos com ACC				
Culturas	CORREL	BIAS	MAE	RMSE
Feijão-sertão	0,79	0,0	101	118
Mandioca-sertão	0,69	0,0	683	857
Milho-sertão	0,72	0,0	99	124
Feijão-agreste	0,76	0,0	76	96
Mandioca-agreste	0,74	0,0	1009	1245
Milho-agreste	0,74	0,0	94	130
Feijão-leste	0,67	0,0	47	65
Mandioca-leste	0,64	0,0	482	660
Milho-leste	0,67	0,0	51	65

Em resumo, a correlação média da simulação das produções com modelos não calibrados foi de 0,79 versus 0,71 das simulações com modelos calibrados. O MAE foi igual nas duas situações, em torno de 294 kg/ha na média das três culturas em todas as mesorregiões, enquanto o RMSE foi levemente superior também das simulações com modelos não calibrados, em torno de 366 kg/ha versus 373 kg/ha.

6. CONCLUSÕES

Buscou-se nessa pesquisa de dissertação investigar a previsibilidade da produção de três culturas de ciclo curto nas mesorregiões alagoanas usando-se como variável preditora a precipitação acumulada no semestre mais chuvoso de tais mesorregiões, que devido a pequena extensão territorial de Alagoas, é homogênea relativa ao semestre que se estende de abril a setembro. O período de análise foi de 1974 a 2014, ou 41 anos de dados avaliados.

Utilizando a técnica de análise de correlações canônicas (ACC), demonstrou-se que é possível prever as safras anuais dessas culturas usando-se como variável preditora a precipitação do semestre AMJJAS, obtendo-se valores plausíveis aos das observações, com valores de correlações estatisticamente significantes e erros dentro da normalidade, dentro do intervalo do desvio padrão das observações.

Em seguida, usou-se a precipitação estimada por oito modelos do CMIP6 de 1974 a 2014 para simular a produção das culturas nas mesorregiões, e com relação ao obtido com os modelos, tem-se as principais conclusões a seguir.

1- A ACC foi, também, eficiente para corrigir os altos vieses da precipitação dos modelos em relação as observações;

2- A simulação das produções das culturas usando-se a precipitação dos modelos corrigidas via ACC foram apenas levemente superiores às mesmas simulações usando-se a precipitação desses modelos sem nenhuma correção de viés;

3- Aplicando-se o conceito de ensemble, a simulação da produção das culturas usando-se como variável preditora a média da precipitação de todos os modelos após calibração com ACC não foi superior as mesmas simulações usando-se a média da precipitação dos modelos sem a calibração;

4- Ainda se usando o conceito de ensemble, a melhor simulação da produção das culturas nas mesorregiões é a proveniente da média simples de cada simulação obtida com cada modelo, com ou sem calibração da precipitação via ACC.

5- A simulação proveniente da média simples das simulações usando a precipitação sem calibração dos modelos foi levemente superior as obtidas com calibração.

A síntese desses resultados leva a uma conclusão diferente da hipótese da pesquisa, que era a de que qualquer simulação da produção das culturas proveniente de modelos com a precipitação corrigida com ACC superaria as simulações usando-se a precipitação dos modelos sem qualquer tipo de pós processamento.

Por fim, demonstrou-se que a precipitação tende a ser a variável resposta que melhor representa a produção de culturas de ciclo curto e de subsistência nas mesorregiões alagoanas, uma vez que são praticadas basicamente em regime de sequeiro.

7. REFERENCIAS BIBLIOGRÁFICAS

ALMAZROUI, M.; ASHFAQ, M.; ISLAM, M. N.; RASHID, I. U.; KAMIL, S.; ABID, M. A.; et al. Assessment of CMIP6 performance and projected temperature and precipitation changes over South America. **Earth Systems and Environment**, v. 5, p. 155–183, 2021a.

ALMAZROUI, M.; ISLAM, M. N.; SAEED, F.; SAEED, S.; ISMAIL, M.; EHSAN, M. A.; et al. Projected changes in temperature and precipitation over the United States, Central America, and the Caribbean in CMIP6 GCMs. **Earth Systems and Environment**, v. 5, p. 1–24, 2021b.

ALMEIDA, T.N. **Impactos na produtividade do feijão na região Nordeste do Brasil sob condições do cenário climático RCP 4.5**. Dissertação de Mestrado, 77p. Instituto de Ciências atmosféricas – UFAL, Maceió, 2021.

ANDRADE, J.; BASCH, G. Clima e estado do tempo. Fatores e elementos do clima. Classificação do clima. In: SHAHIDAN, Shakib. et al. **Hidrologia agrícola**. 1ª edição. Évora: ICAAM- ECT Universidade de Évora, 2012, cap. 3.

ANGELO, C. IPCC AR6, WG2: RESUMO. **Observatório do Clima**, Fonte: IPCC AR6 WG2 Summary for Policymakers. Disponível em: <https://www.oc.eco.br/wp-content/uploads/2022/02/OC-IPCC-FACTSHEET21.pdf>. Acessado em janeiro 2023.

ARAUJO, P.H.C.; SILVA, F.F.; GOMES, M.F.M.; FÉRES, J.G.; BRAGA, M.J. Uma análise do impacto das mudanças climáticas na produtividade agrícola da região Nordeste do Brasil. **Revista Econômica do Nordeste**, v. 45, n. 3, p. 46-57, 2014.

BARNSTON, A.G.; TIPPETT, M.K. Do Statistical Pattern Corrections Improve Seasonal Climate Predictions in the North American Multimodel Ensemble Models? **Journal of Climate**, v. 30, n. 20, p. 8335–8355, 2017.

BENNELL, M.R.; CLEUGH, H.A.; LEYS, J.F.; HEIN, D. The effect of hot dry wind on the pod set of faba bean (*Vicia faba*) cv. Fiord: A preliminary wind tunnel study. **Australian Journal of Experimental Agriculture**, v. 47, n. 12, p. 1468-1475. 2007.

CAMPELO, L.; SANTOS E SILVA, C.M.; BEZERRA, B.; MUTTI, P.R. Analysis of Climate Extreme Indices in the MATOPIBA Region, Brazil. **Pure and Applied Geophysics**, v. 177, n. 4, 2020.

COELHO, J.D.; XIMENES, L.F. Feijão: Produção e Mercado. **Caderno setorial ETENE**, Ano 5, n. 143, p. 1-7, 2020.

CONTINI, E.; MOTA, M.M.; MARRA, R.; BORGHI, E.; MIRANDA, R.A.; SILVA, A.F.; SILVA, D.D.; MACHADO, J.R.A.; COTA, L.V.; COSTA, R.V.; MENDES, S.M. Milho - Caracterização e Desafios Tecnológicos. **EMBRAPA - Série Desafios do Agronegócio Brasileiro (NT2)**, 2019.

COSTA, R.L.; BAPTISTA, G.M.M.; GOMES, H.B.; SILVA, F.D.S.; DA ROCHA JÚNIOR, R.L.; SALVADOR, 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, 2020.

DA ROCHA JÚNIOR, R.L.; DOS SANTOS SILVA, F.D.; LISBOA COSTA, R.; BARROS GOMES, H.; HERDIES, D.L.; RODRIGUES DA SILVA, V.P.; CANDIDO XAVIER, A. Analysis of the Space-Temporal Trends of Wet Conditions in the Different Rainy Seasons of Brazilian Northeast by Quantile Regression and Bootstrap Test. **Geosciences**, v. 9, p. 457, 2019.

DA ROCHA JÚNIOR, R.L.; SILVA, F.D.S.; COSTA, R.L.; GOMES, H.B.; PINTO, D.D.C.; HERDIES, D.L. Bivariate Assessment of Drought Return Periods and Frequency in Brazilian Northeast Using Joint Distribution by Copula Method. **Geosciences**, v. 10, p. 135, 2020.

DANTAS, L.G.; DOS SANTOS, C.A.C.; SANTOS, C.A.G.; MARTINS, E.S.P.R.; ALVES, L.M. Future Changes in Temperature and Precipitation over Northeastern Brazil by CMIP6 Model. **Water**, v. 14, p. 4118, 2022.

ESQUIVEL, A.; LLANOS-HERRERA, L.; AGUDELO, D.; PRAGER, S.D.; FERNANDES, K.; ROJAS, A.; VALENCIA, J.J.; RAMIREZ-VILLEGAS, J. Predictability of seasonal precipitation across major crop growing areas in Colombia. **Climate Services**, v. 12, p. 36-47, 2018.

EYRING, V.; BONY, S.; MEEHL, G. A.; SENIOR, C. A.; STEVENS, B.; STOUFFER, R. J.; TAYLOR, K.E. Overview of the coupled model intercomparison project phase 6 (CMIP6)

experimental design and organization. **Geoscientific Model Development**, v. 9, p. 1937–1958, 2016.

FAO. **Produzir mais com menos: mandioca: um guia para a intensificação sustentável da produção**. Roma, 2013. Informe de política. Disponível em: <<http://www.fao.org/3/a-i2929o.pdf>>. Acesso em: 14 maio de 2023.

FARIAS, A.R.N.; ALVES, A.A.C.; SILVA, A.F.; SOUZA, A.S. et al. **Sistema de Produção de Mandioca no Semiárido**. Embrapa Mandioca e Fruticultura, 63p, 2020.

FIRPO, M.A.F.; GUIMARÃES, B.S.; DANTAS, L.G.; SILVA, M.G.B.; ALVES, L.M.; CHADWICK, R.; LLOPART, M.P.; OLIVEIRA, G.S. Assessment of CMIP6 models' performance in simulating present-day climate in Brazil. **Frontiers in Climate**, v. 4, p. 948499, 2022.

GUARDA, V.D.A.; CAMPOS, L.J.M. **Bases ecofisiológicas da assimilação de carbono e suas implicações na produção de forragem**. 1ª edição. PALMAS – TO: Embrapa Pesca e aquicultura, 2014.

GUERRA, A.F.; SILVA, D.B. da; RODRIGUES, G.C. Manejo de irrigação e fertilização nitrogenada para o feijoeiro na região dos Cerrados. **Pesquisa Agropecuária Brasileira**, Brasília, v.35, n.6, p.1229-1236, 2000.

HAM, S.; JEONG, Y. Characteristics of Subseasonal Winter Prediction Skill Assessment of GloSea5 for East Asia. **Atmosphere**, v. 12, p. 1311, 2021.

HODGES, L.; SURATMAN, M.N.; BRANDLE, J.M.; HUBBARD, K.G. Growth and Yield of snap beans as affected by wind protection and microclimate changes due to shelterbelts and planting dates. **HortScience**, v. 39, n. 5, p. 996-1004. 2004.

HOFSTRA, N.; HAYLOCK, M.; NEW, M.; JONES, P.; FREI, C. Comparison of six methods for the interpolation of daily, European climate data. **Journal of Geophysical Research: Atmospheres**, v. 113, n. D21, 2008.

HOSSAIN, Z.; AZAD, A.K.; KARMAKAR, S.; MONDAL, N.I.; DAS, M.K.; RAHMAN, M.; HAQUE, A. Assessment of Better Prediction of Seasonal Rainfall by Climate Predictability

Tool (CPT) using Global Sea Surface Temperature in Bangladesh. **Preprints.org** 2019, 2019010023.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. Summary for Policymakers. In: Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press, 2021. Disponível em <https://www.ipcc.ch/report/ar6/wg1/> Acesso em:6 mar. 2023.

International Research Institute for Climate and Society, 2006: <http://iridl.ldeo.columbia.edu/outreach/software/index.html>.

KATZ, R.W.; PARLANGE, M.B.; TEBALDI, C. Stochastic modelling of the effects of large-scale circulation on daily weather in the southeastern US. **Climatic Change**, v. 60, p. 189-216, 2003.

KLUG, L.B.; MARENGO, J.A.; LUEDEMANN, G. **Mudanças climáticas e os desafios brasileiros para implementação da nova agenda urbana.** 2016. Disponível em <<https://repositorio.ipea.gov.br/handle/11058/9184>>. Acesso em janeiro de 2023.

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.; SILVA, B.K.N. Método Alternativo de Zoneamento Agroclimático do Milho para o Estado de Alagoas. **Revista Brasileira de Meteorologia**, v. 35, p. 1057-1067, 2021.

LLOPART, M.; DOMINGUES, L. M.; TORMA, C.; GIORGI, F.; DA ROCHA, R. P.; AMBRIZZI, T.; et al. (2021). Assessing changes in the atmospheric water budget as drivers for precipitation change over two CORDEX-CORE domains. **Climate Dynamics**, v. 57, p. 1615–1628, 2021.

LY, Y.; GUO, J.; LI, J.; HAN, Y.; XU, H.; GUO, X.; et al. Increased turbulence in the Eurasian upper-level jet stream in winter: past and future. **Earth and Space Science**, v. 8, e2020EA001556, 2021.

MARTINS, M.A. **Estimativa de produtividade das culturas do milho e do sorgo a partir de modelos agrometeorológicos em algumas localidades da região nordeste do Brasil.** SP: INPE, 2012.

MASSON-DELMOTTE, V.; ZHAI, P.; PIRANI, A.; CONNORS, S.L.; PÉAN, C.; BERGER, S.; et al. IPCC, 2021: **Climate Change 2021: The Physical Science Basis**. Cambridge University In Press.

MEEHL, G.A.; BOER, G.J.; COVEY, C.; LATIF, M.; STOUFFER, R.J. The Coupled Model Intercomparison Project (CMIP). **Bulletin of the American Meteorological Society**, 2000. DOI: 10.1175/1520-0477(2000)081<0313:TCMIPC>2.3.CO;2.

MILLER, S.; MISHRA, V.; ELLENBURG, W.L.; ADAMS, E.; ROBERTS, J.; LIMAYE, A.; GRIFFIN, R. Analysis of a Short-Term and a Seasonal Precipitation Forecast over Kenya. **Atmosphere**, v. 12, p. 1371, 2021.

MONTEVERDE, C.; DE SALES, F.; JONES, C. Evaluation of the CMIP6 Performance in Simulating Precipitation in the Amazon River Basin. **Climate**, v. 10, p. 122, 2022.

NOBRE, C.A.; REID, J.; VEIGA, A.P.S. **Fundamentos científicos das mudanças climáticas**. 1ª edição. São José dos Campos: INPE, 2012.

O'NEILL, B.C.; TEBALDI, C.; VAN VUUREN, D.P.; EYRING, V.; FRIEDLINGSTEIN, P.; HURTT, G.; KNUTTI, R.; KRIEGLER, E.; LAMARQUE, J-F.; LOWE, J.; MEEHL, G.A.; MOSS, R.; RIAHI, K., SANDERSON, B.M. The scenario model intercomparison project (Scenario MIP) for CMIP6. **Geoscientific Model Development**, v. 9, p. 3461–3482, 2016.

OLIVEIRA, F.A.; SILVA, J.J.S. Evapotranspiração, índice de área foliar e desenvolvimento radicular do feijão irrigado. **Pesquisa Agropecuária Brasileira**, Brasília, v.25, n.3, p.317-322, 1990.

OLIVEIRA, L.P.M.; SILVA, F.D.S.; COSTA, R.L.; ROCHA JÚNIOR, R.L.; GOMES, H.B.; PEREIRA, M.P.S.; MONTEIRO, L.A.; SILVA, V.P.R. Impacto das Mudanças Climáticas na Produtividade da Cana de Açúcar em Maceió. **Revista Brasileira de Meteorologia**, v. 35, p. 969-980, 2021.

ORDOÑEZ, L.; VALLEJO, E.; AMARILES, D.; MESA, J.; ESQUIVEL, A.; LLANOS-HERRERA, L.; PRAGER, S.D.; SEGURA, C.; VALENCIA, J.J.; DUARTE, C.J.; ROJAS, D.C.; OBANDO, D.; RAMIREZ-VILLEGAS, J. Applying agroclimatic seasonal forecasts to improve rainfed maize agronomic management in Colombia. **Climate Services**, v. 28, p. 100333, 2022.

ORTEGA, G.; ARIAS, P. A.; VILLEGAS, J. C.; MARQUET, P. A.; AND NOBRE, P. (2021). Present-day and future climate over central and South America according to CMIP5/CMIP6 models. **International Journal of Climatology**. v. 41, p. 6713–6735, 2021.

PAREDES-TREJO, F.; BARBOSA, H.; DOS SANTOS, C.A.C. Evaluation of the Performance of SM2RAIN-Derived Rainfall Products over Brazil. **Remote Sensing**, v. 11, p. 1113, 2019.

PEIXOTO, I.C. **Potencial preditivo da produtividade do milho nas mesoregiões do nordeste brasileiro**. Dissertação de Mestrado, 54p. Instituto de Ciências atmosféricas – UFAL, Maceió, 2021.

PEREIRA, A.R.; MACHADO, E.C. **Análise quantitativa do crescimento de comunidade vegetais**. Instituto Agronômico. Campinas, SP, 33p. (Boletim Técnico, 114). 1987.

RIBEIRO, A.G. As escalas do clima. **Boletim de Geografia Teorética**, v. 23, n. 46, p. 288-294, 1993.

ROCHA JUNIOR, R.L.; PINTO, D.D.C.; DOS SANTOS SILVA, F.D.; GOMES, H.B.; GOMES, H.B.; COSTA, R.L.; PEREIRA, M.P.S.; PENA, M.; COELHO, C.A.S.; HERDIES, D.L. An Empirical Seasonal Rainfall Forecasting Model for the Northeast Region of Brazil. **Water**, v. 13, p. 1-21, 2021.

SILVA, E.H.L.; SILVA, F.D.S.; DA SILVA JUNIOR, R.S.; PINTO, D.D.C.; COSTA, R.L.; GOMES, H.B.; CABRAL JÚNIOR, J.B.; DE FREITAS, I.G.F.; HERDIES, D.L. Performance Assessment of Different Precipitation Databases (Gridded Analyses and Reanalyses) for the New Brazilian Agricultural Frontier: SEALBA. **Water**, v. 14, p. 1473, 2022.

SILVA, E.R.L.D.G.; SILVA, M.E.S. Memória de eventos ENOS na precipitação da América do Sul. **Revista do Departamento de Geografia-USP**, v. 30, p. 34-55, 2015.

SILVA, F.D.S.; COSTA, R.L.; ANTONIO, M.A.V.; AFONSO, E.O.; SANTOS, D.M.; MATEUS, N.P.A.; ANTONIO, J.F. Observed trends of potential evapotranspiration in the state of Alagoas (1961-2016). **Revista Brasileira de Geografia Física**, v. 11, p. 28-43, 2018.

SILVA, J.S.; CABRAL JÚNIOR, J.B.; RODRIGUES, D.T.; SILVA, F.D.S. Climatology and significant trends in air temperature in Alagoas, Northeast Brazil. **Theoretical and Applied Climatology**, v. 151, p. 1-20, 2023.

SILVA, P.E.; SILVA, C.M.S.; SPYRIDES, M.H.C.; ANDRADE, L.M.B. Análise de Índices de Extremos Climáticos no Nordeste e Amazônia Brasileira para o Período entre 1980 a 2013. **Anuário do Instituto de Geociências**, v. 42, p. 137–148, 2019.

SINGH, A.; ACHARYA, N.; MOHANTY, U.C.; MISHRA, G. Performance of MultiModel Canonical Correlation Analysis (MMCCA) for prediction of Indian summer monsoon rainfall using GCMs output. **Computes Rendus Geoscience**, v. 345(2), p. 62-72, 2012.

STEVENS, K.; RUSCHER, P.H. Large scale climate oscillations and mesoscale surface meteorological variability in the Apalachicola Chattahoochee-Flint River Basin. **Journal of Hydrology**, v. 517, p. 700-714, 2014.

WILKS, D.S. **Statistical Methods in the Atmospheric Sciences**, 3rd ed.; Academic Press: Cambridge, MA, USA, 2011.

XAVIER, A.C.; KING, C.W.; SCANLON, B.R. Daily gridded meteorological variables in Brazil (1980-2013). **International Journal of Climatology**, v. 36, n. 6, p. 2644-2659, 2016.

XAVIER, A.C.; SCANLON, B.R.; KING, C.W.; ALVES, A.I. New improved Brazilian daily weather gridded data (1961–2020). **International Journal of Climatology**, v. 42, n. 16, p. 8390– 8404, 2022.