

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

CLOVIS ISAAC SILVA DE LIMA

**MODELAGEM AGROMETEOROLÓGICA PARA  
ESTIMATIVA DA PRODUTIVIDADE DO MILHO EM  
ALAGOAS: PRESENTE E FUTURO**

Maceió – AL

2019

CLOVIS ISAAC SILVA DE LIMA

**MODELAGEM AGROMETEOROLÓGICA PARA  
ESTIMATIVA DA PRODUTIVIDADE DO MILHO EM  
ALAGOAS: PRESENTE E FUTURO**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Meteorologia do Instituto de Ciências Atmosféricas da Universidade Federal de Alagoas, como requisito parcial para obtenção do Título de Mestre em Meteorologia, área de concentração Processos de Superfície Terrestre.

Orientador: Prof. Dr. Fabrício Daniel dos Santos Silva.

Maceió – AL

2019

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

Bibliotecária Responsável: Helena Cristina Pimentel do Vale – CRB4/661

L732m Lima, Clovis Isaac Silva de.

Modelagem agrometeorológica para estimativa da produtividade do milho em Alagoas : presente e futuro / Clovis Isaac Silva de Lima. – 2020.  
62 f. : il.

Orientador: Fabrício Daniel dos Santos Silva.  
Dissertação (mestrado em Meteorologia : Processos de Superfície Terrestre) – Universidade Federal de Alagoas. Instituto de Ciências Atmosféricas. Maceió, 2019.

Bibliografia: f. 54-62.

1. Agrometeorologia. 2. Modelo computacional. 3. Variabilidade climática – Alagoas. 4. Milho – Cultivo e produtividade. I. Título.

CDU: 551.58:004.028



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

## CERTIFICADO DE APRESENTAÇÃO

N.º de ordem: MET-UFAL-MS-168.

***"MODELAGEM AGROMETEOROLÓGICA PARA ESTIMATIVA DA  
PRODUTIVIDADE DO MILHO EM ALAGOAS: PRESENTE E FUTURO."***

*Clovis Isaac Silva de Lima*

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:

*Fabício Daniel dos Santos Silva*

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

*Djane Fonseca da Silva*

Prof.ª Dra. Djane Fonseca da Silva  
(Membro Interno)

*Rafael Lisboa Costa*

Prof.ª Dra. Rafael Lisboa Costa  
(Membro Interno)

*Jório Bezerra Cabral Junior*

Prof. Dr. Jório Bezerra Cabral Junior  
(Membro Externo)

Dezembro/2019

Dedico à minha família, em especial, minha esposa e filho.

## AGRADECIMENTOS

A todos os meus amigos do curso: “Vanessa, Lívia, Aline, Edson, Ismael, Laurizio, Bruno, Bruno Cesar, Gomez, Marcelo, Hugo, Alexandra, Rodrigo, Dagmer, Sherlly, Iwldson e David”, aos professores: Natália, Vladmir, Georgenes, Rosiberto, Luciene, Djane, Amorim e Fabrício a esses mestres da vida, obrigado pela paciência que Deus os ilumine.

A Fundação de Amparo à Pesquisa do Estado de Alagoas - FAPEAL, que firmou uma parceria conosco no último ano e potencializou os resultados dessa pesquisa, quero deixar registrada a minha gratidão a essa instituição que acredita na ciência e no potencial de alunos do estado de Alagoas.

A minha família que abriu mão de minha companhia, a minha maravilhosa e amada esposa que me suportou e me ajudou durante todo o processo, ao meu filho que é a razão pela qual cheguei até aqui.

**Jesus** não tem como escrever minha gratidão pela graça alcançada, toda honra e glória seja dada ao senhor.

## RESUMO

A Produção do milho é muito importante no Estado de Alagoas, seja sob o ponto de vista alimentar ou como opção socioeconômica para a agricultura familiar. Dessa forma essa pesquisa teve como objetivo avaliar a variação da produtividade futura a partir de cenários de mudanças climáticas, utilizando-se para isso um modelo agrometeorológico calibrado para as condições edafoclimáticas do Estado de Alagoas. O primeiro objetivo da pesquisa foi determinar a melhor época de semeadura para cada município e mesorregião de Alagoas, baseando-se no rendimento médio obtido para cada decêndio do ano no período 1980-2015, a partir de dados observados de alta resolução. Para isso, foi empregada a técnica de *downscaling* estatístico para regionalização de cenários de mudanças climáticas para quatro localidades de referência nas três grandes mesorregiões do Estado, a fim de estudar a variação futura do rendimento da cultura mediante tais cenários, para o horizonte de 2011 a 2100, dividido nos subperíodos 2011-2040, 2041-2070 e 2071-2100. As projeções futuras foram geradas para dois cenários climáticos oriundos do quinto relatório de mudanças climáticas do IPCC (*Intergovernmental Panel of Climate Change*), RCP4.5 e RCP8.5, a partir da média do conjunto de sete modelos climáticos globais que compõem o quinto relatório do IPCC: CANESM2 (Canadá), CNRM-CM5 e IPSL-CM5A-MR (França), GFDL-ESM2M (Estados Unidos), MIROC-ESM (Japão), MPI-ESM-MR (Alemanha), e o NORESM1-M (Noruega). Os cenários climáticos futuros apontam para aumento das temperaturas e conseqüentemente da evapotranspiração potencial, e redução da precipitação, principalmente a partir de 2011-2040. Em comparação com a produtividade observada do IBGE no período de 1980 a 2015, a simulação da produtividade futura com os dados provenientes dos cenários indica uma redução do rendimento em cerca de 50%, levemente mais pronunciada no cenário RCP8.5 com aproximadamente 65%.

**Palavras-chave:** Modelo agrometeorológico, cenários climáticos futuros, produtividade.

## **ABSTRACT**

Corn production is very important in the State of Alagoas, either from the food point of view or as a socioeconomic option for family farming. Thus, this research aimed to evaluate the variation of future productivity from climate change scenarios, using for this purpose an agrometeorological model calibrated for the edaphoclimatic conditions of the State of Alagoas. The first objective of the research was to determine the best sowing time for each municipality and mesoregion of Alagoas, based on the average yield obtained for each decade of the year in the period 1980-2015, from high resolution observed data. For this, the statistical downscaling technique was used for regionalization of climate change scenarios for four reference locations in the three major mesoregions of the State, in order to study the future variation of crop yield under such scenarios, for the horizon of 2011 to 2100, divided into subperiods 2011-2040, 2041-2070 and 2071-2100. Future projections were generated for two climate scenarios from the IPCC's fifth climate change report, RCP4.5 and RCP8.5, from the average of the seven global climate models that make up the fifth report. IPCC: CANESM2 (Canada), CNRM-CM5 and IPSL-CM5A-MR (France), GFDL-ESM2M (United States), MIROC-ESM (Japan), MPI-ESM-MR (Germany), and NORESM1-M (Norway). Future climate scenarios point to higher temperatures and consequently to potential evapotranspiration, and reduced precipitation, especially from 2011-2040. Compared with IBGE's observed productivity from 1980 to 2015, the simulation of future productivity with scenario data indicates a yield reduction of around 50%, slightly more pronounced in the RCP8.5 scenario with approximately 65%.

**Keywords:** Agrometeorological model, future climate scenarios, yield.



## LISTA DE FIGURAS

<b>Figura 1</b> - Forçante radiativa dos RCPs. Fonte: Van Vuuren et al. (2011).....	15
<b>Figura 2</b> - (a) Distribuição espacial das estações convencionais e automáticas do INMET nas diferentes mesorregiões de Alagoas e (b) localização espacial das sedes municipais em que foram extraídas séries temporais de PREC e ETP da análise gradeada. Fonte: Xavier et Al. (2016).....	20
<b>Figura 3.</b> (a)Imagem da grade sobre o parte da região Nordeste e Estado de Alagoas utilizada para estabelecer relações preditor (reanálises) - preditando (observações de superfície);e (b)distribuição espacial das estações convencionais do INMET em Alagoas.....	28
<b>Figura 4.</b> Produtividades observadas e simuladas do milho nas cidades Água Branca, Pão de Açúcar, Palmeira dos Índios e Porto de Pedras.....	33
<b>Figura 5.</b> Produtividade relativa percentual média do milho para o primeiro, segundo e terceiro decêndios de janeiro a dezembro, em sequência.....	35
<b>Figura 6</b> - Produtividade potencial média do milho para as diferentes mesorregiões do Estado de Alagoas.....	38
<b>Figura 7</b> - Climatologia da precipitação acumulada observada x simulada pelos MCGs e observada x ensemble de todos os MCGs para Água Branca (a, b), Pão de Açúcar (c,d), Palmeira dos Índios (e,f), e Porto de Pedras (i,j).....	40
<b>Figura 8</b> - Climatologia da temperatura máxima média observada x simulada pelos MCGs e observada x ensemble de todos os MCGs para Água Branca (a, b), Pão de Açúcar (c,d), Palmeira dos Índios (e,f), e Porto de Pedras (i,j).....	41
<b>Figura 9</b> - Climatologia da temperatura mínima média observada x simulada pelos MCGs e observada x ensemble de todos os MCGs para Água Branca (a, b), Pão de Açúcar (c,d), Palmeira dos Índios (e,f), e Porto de Pedras (i,j).....	42
<b>Figura 10-</b> Na sequência, climatologia futura da ETP obtida do ensemble dos MCGs para o cenário RCP4.5 em Água Branca,Pão de Açúcar, Palmeira dos Índios e Porto de Pedras. ....	45
<b>Figura 11</b> - Na sequência, climatologia futura da precipitação obtida do ensemble dos MCGs para o cenário RCP4.5 em Água Branca, Pão de Açúcar, Palmeira dos Índios e Porto de Pedras.....	46

<b>Figura 12</b> –Pluma de Produtividade potencial de cada MCG de 2011 a 2100 no cenário RCP4.5.....	47
<b>Figura 13</b> - Na sequência, climatologia futura da ETP obtida do ensemble dos MCGs para o cenário RCP8.5 em Água Branca, Pão de Açúcar, Palmeira dos Índios e Porto de Pedras Comportamento da ETP no cenário 8.5.....	48
<b>Figura 14</b> – Na sequência, climatologia futura da precipitação obtida do ensemble dos MCGs para o cenário RCP8.5 em Água Branca, Pão de Açúcar, Palmeira dos Índios e Porto de Pedras.....	49
<b>Figura 15</b> - Pluma de Produtividade potencial de cada MCG de 2011 a 2100 no cenário RCP8.5.....	50

## LISTA DE TABELAS

<b>Tabela 1</b> - Medidas de performance estatística para o período de validação da precipitação.	43
<b>Tabela 2</b> - Medidas de performance estatística para o período de validação da temperatura máxima.....	44
<b>Tabela 3</b> - Medidas de performance estatística para o período de validação da temperatura mínima.....	44

## LISTA DE SIGLAS

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

# Sumário

<b>1. INTRODUÇÃO .....</b>	<b>10</b>
<b>1.1. OBJETIVOS.....</b>	<b>12</b>
1.1.1. Geral .....	12
1.1.2. Específicos.....	12
<b>2. REVISÃO BIBLIOGRÁFICA .....</b>	<b>13</b>
<b>2.1. MILHO NO BRASIL.....</b>	<b>13</b>
<b>2.2. MODELOS CLIMÁTICOS GLOBAIS E CENÁRIOS DE MUDANÇAS CLIMÁTICAS.....</b>	<b>14</b>
<b>2.3. DOWNSCALING ESTATÍSTICO .....</b>	<b>16</b>
<b>3. MATERIAIS E MÉTODOS .....</b>	<b>19</b>
<b>3.1. DADOS E ÁREA DE ESTUDO.....</b>	<b>19</b>
<b>3.2. CALIBRAÇÃO DO MODELO AGROMETEOROLÓGICO .....</b>	<b>22</b>
3.2.1. PROCESSAMENTO DO <i>DOWNSCALING</i> .....	24
<b>4. RESULTADOS E DISCUSSÕES .....</b>	<b>32</b>
<b>4.1 CALIBRAÇÃO DO MODELO AGROMETEOROLÓGICO .....</b>	<b>32</b>
<b>4.2 ZONEAMENTO DA MELHOR ÉPOCA DE SEMEADURA .....</b>	<b>33</b>
<b>4.3. PROJEÇÕES FUTURAS PARA A SEMEADURA DO MILHO EM ALAGOAS .....</b>	<b>38</b>
4.3.1 CALIBRAÇÃO DO MODELO DE DOWNSCALING ESTATÍSTICO .....	38
4.3.2 VALIDAÇÃO DO MODELO DE DOWNSCALING ESTATÍSTICO.....	43
4.3.3 CENÁRIOS CLIMÁTICOS FUTUROS: RCP4.5 .....	44
4.3.4 CENÁRIOS CLIMÁTICOS FUTUROS: RCP8.5 .....	48
<b>5 CONCLUSÕES.....</b>	<b>52</b>
<b>6 SUGESTÕES PARA TRABALHOS FUTUROS .....</b>	<b>53</b>
<b>7 REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>54</b>

## 1. INTRODUÇÃO

A produtividade das culturas, incluindo-se o milho, depende fortemente das condições climáticas. Experimentos de campo foram fundamentais para o aprimoramento de modelos que conseguissem representar bem a interação clima e agricultura (GREATREX, 2012). Entre os objetivos em se desenvolver modelos numéricos eficientes na representação do ciclo de vida das culturas estão a definição de datas ótimas para semeadura, aplicação de técnicas de manejo agrícola e, principalmente, previsibilidade das safras em resposta ao clima (JAME e CUTFORT, 1996; JONES ET AL, 2003; MURTHY, 2004; ASSAD ET AL, 2007; HSIAO, 2009; LORENÇONI, 2010; CORRÊA, 2011; SCARPARE, 2011; HOOGENBOOM ET AL, 2012; GARCÍA VILA E FERERES, 2012, MONTEIRO ET AL, 2017).

Toda esta evolução a fim de pesquisar o papel crucial do clima na produtividade é fundamental para a agricultura de sequeiro, pois esta é responsável por aproximadamente 80% das áreas cultiváveis no mundo e 60% das áreas cultivadas com alimentos (FAO, 2011; CONAB, 2018).

Apesar da melhoria nos resultados das simulações de produtividade das culturas em função do clima, uma preocupação adicional consiste em compreender de que forma a ação antrópica influenciará no rendimento agrícola futuro (HOLDEN E BRERETON, 2003; SILVA ET AL, 2012; CAMILO ET AL, 2018; RAMIREZ-CABRAL ET AL, 2017; MURRAY-TORTAROLO ET AL, 2018)

Diversos estudos, principalmente a partir das últimas décadas após o surgimento do IPCC (Sigla em inglês para Painel Intergovernamental sobre Mudanças Climáticas), tem demonstrado que as mudanças nos padrões climáticos já são evidentes em todo o planeta (FRICH, 2002; KÜRBIS ET AL, 2009; SKANSI ET AL, 2013; SANTOS ET AL, 2015; SALVIANO AT AL, 2016). A maior parte dos estudos sobre mudanças climáticas em séries de dados observados mostra a dificuldade de se encontrar tendências consistentes, e significativas, ao se analisar dados de precipitação, enquanto foram encontradas tendências de aumento muitas vezes significativas em índices relativos aos dados de temperatura, nas mais diversas regiões do globo.

Em particular para a região Nordeste do Brasil, a tendência predominantemente positiva no aumento das temperaturas, principalmente das temperaturas mínimas, diminuindo a amplitude térmica diária, pode provocar diretamente um aumento da evapotranspiração potencial (ETP) desta região, afetando a produtividade agrícola, associada também a maior

frequência de eventos de secas (MARENGO ET AL, 2009; BRITO ET AL, 2017; MARENGO ET AL, 2017; ROSSATO ET AL, 2017).

No caso do Nordeste, que tem a maior parte de sua área inserida no clima semiárido, o aumento na ETP associado a alta variabilidade espaço-temporal da precipitação, pode prejudicar ainda mais as atividades agrícolas, uma vez que esta tendência continua para diferentes cenários futuros de mudanças climáticas.

O milho é uma das culturas mais antigas do mundo, sendo atualmente amplamente cultivado, desempenhando também um papel fundamental no sistema de produção alimentar brasileiro (MARTINS, 2012). O elevado potencial produtivo, composição química e valor nutritivo fazem com que esse cereal seja considerado mundialmente como um dos mais importantes e devido a sua versatilidade de uso, é utilizado tanto na indústria, como na alimentação humana e animal.

Há uma grande diversidade nas condições de cultivo do milho no Brasil. Observa-se uma grande parcela de pequenos produtores com agricultura tipicamente de subsistência, sem utilização de insumos modernos, cuja produção é voltada para consumo na propriedade e eventual excedente comercializado, e uma pequena parcela de grandes produtores com alto índice de produtividade, empregando maior área, mais capital e mais tecnologia na produção de milho, alcançando produtividades equivalentes às obtidas em países de agricultura mais avançada.

A maior parte do território do Estado de Alagoas está inserido na porção semiárida do Nordeste, uma região constantemente afetada com efeitos da seca. Por sua susceptibilidade ao insucesso das safras, boa parte dos agricultores são atendidos pelo Seguro da Agricultura Familiar (SEAF) do Programa Garantia Safra (GS), que visa assegurar a renda do agricultor em situações de quebra de safra decorrentes de estiagem ou excesso hídrico. Do ponto de vista da segurança alimentar, o milho é o alimento básico para a maioria da população rural alagoana.

O quinto relatório do IPCC (2013), intitulado Impactos, Adaptação e Vulnerabilidade, alerta para os riscos aos quais estes tipos de atividade agrícola estão fadados. Segundo o documento, os riscos da mudança climática provem da vulnerabilidade (falta de preparo), exposição (pessoas ou bens em perigo) e sobreposição com os riscos (tendências ou eventos climáticos desencadeantes).

## 1.1. OBJETIVOS

### 1.1.1. Geral

Gerar cenários climáticos futuros, e avaliar os impactos na produtividade do milho por meio de um modelo agrometeorológico, comparando com a produtividade atual observada no estado de Alagoas.

### 1.1.2. Específicos

1. **VALIDAR** um modelo agrometeorológico de penalização por déficit hídrico aplicado a cultura do milho em Alagoas;
2. **REALIZAR** um zoneamento agroclimático para identificar a melhor época de semeadura do milho para o Estado de Alagoas baseado no histórico do rendimento médio das safras agrícolas;
3. **GERAR** e validar o *downscaling* estatístico da precipitação e ETP para o estado de Alagoas, a partir de previsões de modelos climáticos globais;
4. **AVALIAR** a produtividade futura do milho em Alagoas, para dois diferentes cenários futuros de emissão de gases do efeito estufa: RCP4.5 e RCP8.5;
5. **COMPARAR** os resultados da produtividade real observada com a gerada a partir dos cenários de mudanças climáticas.



## **2. REVISÃO BIBLIOGRÁFICA**

### **2.1. A CULTURA DO MILHO NO NORDESTE**

O milho tem um alto potencial produtivo e é bastante responsivo à tecnologia, sendo também a espécie vegetal mais utilizada em pesquisas genéticas. É um dos principais casos de sucesso da chamada revolução verde, mesmo em elevados níveis de luz (ALVES, 2007; BATISTA, 2017).

As cultivares de milho são classificadas como híbridos simples, simples modificado, duplo, triplo, ou cultivares de polinização aberta (variedades). As cultivares de híbridos simples tem como vantagens maior uniformidade e potencial produtivo, além da maior uniformidade de plantas e espiga, porém a semente tem o custo mais elevado. Segundo (CUENCA, 2014), predominam no mercado brasileiro o uso de híbridos simples.

Considerando o cultivo do milho, sabe-se que o rendimento é o resultado do potencial genético da semente, das condições edafoclimáticas, do local de semeadura e do manejo adotado na lavoura. A produtividade média mundial de milho tem aumentado de ano para ano, desde a introdução dos híbridos por volta da década de 30. Nos EUA, os ganhos de produtividade de milho foram proporcionais ao aumento do uso de fertilizantes minerais nitrogenados (BALBINOT ET AL, 2015).

O clima é o principal fator responsável pelas oscilações e frustrações das safras agrícolas no Brasil. Diversas análises da produção agrícola apontam alta correlação entre variações de safras, das principais culturas, e as condições meteorológicas e climáticas. Em geral, as condições hídricas são as que mais afetam a produção das lavouras (MONTEIRO, 2013).

A produção de milho também pode ser afetada drasticamente por estiagens curtas, quando coincidentes com o período crítico da cultura. Contrariamente, os rendimentos de grãos podem ser elevados substancialmente pela melhoria do manejo das lavouras, sobretudo pela redução das limitações climáticas, significando dizer que o impacto das adversidades climáticas, em especial das estiagens, é intenso (MONTEIRO, 2013).

Segundo relatório da FAO (2019), para a safra 2019/2020, o Brasil já é o segundo maior exportador mundial e terceiro maior produtor de milho do mundo, com uma safra em torno de 96 milhões de toneladas, sendo responsável por 25% do total mundial das vendas desse produto (CONAB, 2019).

Em contraste a produção mecanizada, boa parte do milho cultivado no Nordeste do Brasil, em particular no Estado de Alagoas, visa a subsistência familiar (consumo próprio das famílias e animais). No entanto, há elevadas taxas de perdas associadas às frequentes estiagens que afetam o Estado. Observaram que, em média, a perda de produtividade associada ao déficit hídrico é intenso no sertão, chegando a atingir média de 78% no município de Pão de Açúcar, de 50% em Palmeira dos Índios, no agreste, e de 30 a 45% e na região litorânea.

## **2.2. MODELOS CLIMÁTICOS GLOBAIS E CENÁRIOS DE MUDANÇAS CLIMÁTICAS**

Modelos Climáticos Globais (MCGs) se baseiam na física que rege a dinâmica dos fluidos e termodinâmica, descrevendo interações entre os componentes do sistema climático, atmosfera, oceanos, biosfera, litosfera, e demais aspectos relevantes para a superfície e equilíbrio energético (SAMPAIO e SILVA DIAS, 2014).

Os MCG's atuais são acoplados com modelos oceânicos, contemplando ainda processos biogeoquímicos. No entanto, apesar dos MCGs caracterizarem bem as condições climáticas globais, ainda é necessário aumentar a confiabilidade em áreas com coberturas vegetais e topografias complexas, e regiões litorâneas (ALLSOPP ET AL, 2003; HUNZIKER ET AL, 2018).

Os MCGs evoluíram muito ao longo das últimas décadas (VANNITSEM e CHOMÉ, 2005; GIORGE, 2019), passando a incorporar dados relativos às emissões de gases de efeito estufa (GEE) para atender a demanda do IPCC e gerar projeções do clima futuro, em horizontes que podem ultrapassar o final do século XXI (JONES ET AL, 2004; RANASINGHE, 2016).

Estas projeções são realizadas de acordo com cenários de mudanças climáticas concebidos pelo IPCC no que concernem aos mais prováveis padrões de evolução da humanidade no consumo dos combustíveis fósseis e emissões de gás carbônico, monóxido de carbono, óxido nitroso, dióxido de enxofre, metano, entre outros gases (HULME ET AL, 1999; NAKICENOVIC ET AL, 2000; PELLEGRINE ET AL, 2017).

Em 2014 foi lançada a mais recente família de cenários no quinto relatório do IPCC (AR5-SYR), ou RCPs de sua sigla em inglês para *Representative Concentration Pathways*. Estes cenários incorporaram aos perfis de emissões, forçantes de cunho político-social


baseados em protocolos de acordos firmados por nações relativos à implementação de políticas públicas voltadas a minimizar as emissões de gases de efeito estufa (MACH ET AL, 2016).

Os cenários são os RCP2.6, RCP4.5, RCP6 e RCP8.5, nomeados desta forma para uma provável faixa de valores de forçamento radiativo no ano 2100 em relação aos valores pré-industriais (+2,6, +4,5, +6,0 e +8,5 W/m<sup>2</sup>, respectivamente).

Esta pesquisa foi conduzida trabalhando-se com os cenários RCP4.5 e RCP8.5. O RCP4.5 é um cenário de equilíbrio no qual o forçamento radiativo total é estabilizado após 2100, sem ultrapassar o nível-alvo de forçante radiativa de 4.5W/m<sup>2</sup> ( $\approx$  650ppm de CO<sub>2</sub> equivalente), enquanto o RCP8.5 é um cenário de alta emissão (ou seja, aumento das emissões de GEE ao longo do tempo) correspondendo a uma via de forçamento radiativo crescente que alcança 8,5W/m<sup>2</sup> ( $\approx$  1370ppm de CO<sub>2</sub> equivalente) até 2100 (VAN VUUREN ET AL, 2011; ALLISON ET AL, 2011; RIAHI ET AL, 2011; WAONGO ET AL, 2018).

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

**Figura 1.** Forçante radiativa dos RCPs. Fonte: VAN VUUREN ET AL (2011).



### 2.3. *DOWNSCALING* ESTATÍSTICO

Os diversos métodos de *downscaling* estatístico são conhecidos também como métodos de desagregação ou refinamento estatístico, podendo ser de ordem temporal, espacial, ou pela combinação destas duas dimensões (FOWLER ET AL, 2007; MARENGO, 2010; ALI ET AL, 2019). Uma revisão detalhada sobre métodos de *downscaling* estatístico é apresentada em FOWLER ET AL (2007).

Métodos de *downscaling* estatístico (MDEs) são fundamentados na premissa de que o clima local está condicionado por dois fatores, aspectos de larga escala da circulação global, como por exemplo as fases ENOS, e características fisiográficas locais tais como topografia, alternância terra/mar nas regiões costeiras e uso da terra (WILBY ET AL, 1997; BRANDS, ET AL, 2011A; BRANDS, ET AL, 2011B; GUTZLER e ROBBINS, 2011; TORMA, 2019).

WILBY ET AL (2013) classificou os MDEs em três categorias. A primeira é baseada na classificação de padrões de tempo. Nesta abordagem, variáveis climáticas locais são relacionadas com classes de tempo de escala sinótica (KAZMI ET AL, 2015); b) Geradores de tempo: são modelos que produzem séries temporais sintéticas de variáveis meteorológicas para uma determinada região (SADDIQUE ET AL, 2019); e c) Modelos de Regressão: estimam relações quantitativas entre preditores oriundos de MCG e variáveis prognósticas locais utilizando modelos empíricos (FOWLER ET AL, 2007; MENDES e MARENGO, 2009). Uma quarta abordagem conhecida como análise de sobrevivência (MAIA e MEINKE, 2010) também pode ser usada para *downscaling* estatístico. No Brasil esse tipo de modelo estatístico foi usado para gerar projeções de início de estação chuvosa em função de preditores derivados do fenômeno ENOS (MAIA ET AL, 2011).

Para o Brasil, alguns estudos utilizando diferentes MDEs merecem destaque. RAMOS (2000) utilizou redes neurais e regressão linear múltipla para previsão sazonal na bacia hidrográfica do Vale do Piancó, na Paraíba, com os dois métodos apresentando boa performance, mas as redes neurais oferecendo desempenho superior à regressão. ROBERTSON ET AL (2004) usaram modelos de cadeias de Markov para simulações da precipitação diária no Estado do Ceará. As simulações foram capazes de capturar relativamente bem mudanças interanuais de precipitação e ocorrência diária de chuva em sequências de 10 dias em algumas estações individuais. VALVERDE ET AL (2005) utilizaram redes neurais e regressão linear múltipla para simulação da precipitação diária de São Paulo, com as redes sendo superiores à regressão, que apresentou elevado viés para os

dias sem ocorrência de chuva. Estes resultados levaram VALVERDE ET AL (2006) a aplicar as mesmas técnicas para toda a região Sudeste, com os modelos apresentando eficiência na simulação das chuvas durante o verão. Para a bacia amazônica, MENDES e MARENGO (2009) aplicaram redes neurais e método de autocorrelações seriais para prognosticar chuvas diárias. Por fim, GONÇALVES ET AL (2010) empregaram redes neurais para simulações do vento a 10m de altura nas regiões Sudeste e Nordeste, com bons resultados, mas com leve superestimativa das velocidades.

A principal vantagem do *downscaling* estatístico em relação ao uso de modelos dinâmicos é computacional, facilitando o uso de grande número de preditores derivados de MCGs. No entanto, são necessárias longas séries de dados observados locais das variáveis de interesse. O *downscaling* estatístico baseia-se na pressuposição de que a relação entre os preditores e a variável-resposta é estacionária, isto é, tenha a propriedade de invariância temporal (WILBY ET AL, 2013).

A forma mais comum de obter a relação estatística, ou empírica, desenvolvida a partir da relação quantitativa entre preditores e preditandos, pode ser entendida como:  $R = F(L)$ , onde R representaria o preditando (a variável climática regional, ou local, por exemplo, precipitação, temperatura ou evapotranspiração obtidas de uma determinada estação meteorológica), e F uma função determinística/estocástica condicionada por L, obtida a partir da relação empírica obtida da respectiva grade associada ao MCG utilizado (SILVA, 2014). Os MDEs combinam as informações dos MCGs as reanálises das observações das variáveis de grande escala, a fim de inferir os modelos de transferência estatística apropriados. Portanto, dois ingredientes básicos dos MDEs são os conjuntos de dados de reanálises e as observações, que são necessários para definir e calibrar os MDE(s) que serão usados posteriormente para gerar cenários futuros (ZORITA e VON STORCH, 1999; HERTIG, 2019).

A habilidade dos MDEs depende da variável, época e região de interesse. Assim, para cada aplicação e estudo de um caso particular, um conjunto de MDEs precisa ser testado e validado para alcançar o máximo de habilidade e uma representação adequada de incertezas. Assim, a validação se torna a principal componente de um MDE (SILVA, 2014).

Cada experimento deve conter todas as informações necessárias para o processo de redução de escala: um conjunto único de preditores, os preditandos e um MDE (COFIÑO ET AL, 2007). Para definir um experimento as três etapas sequenciais devem ser adotadas:

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

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

### **3. MATERIAIS E MÉTODOS**

#### **3.1. DADOS E ÁREA DE ESTUDO**

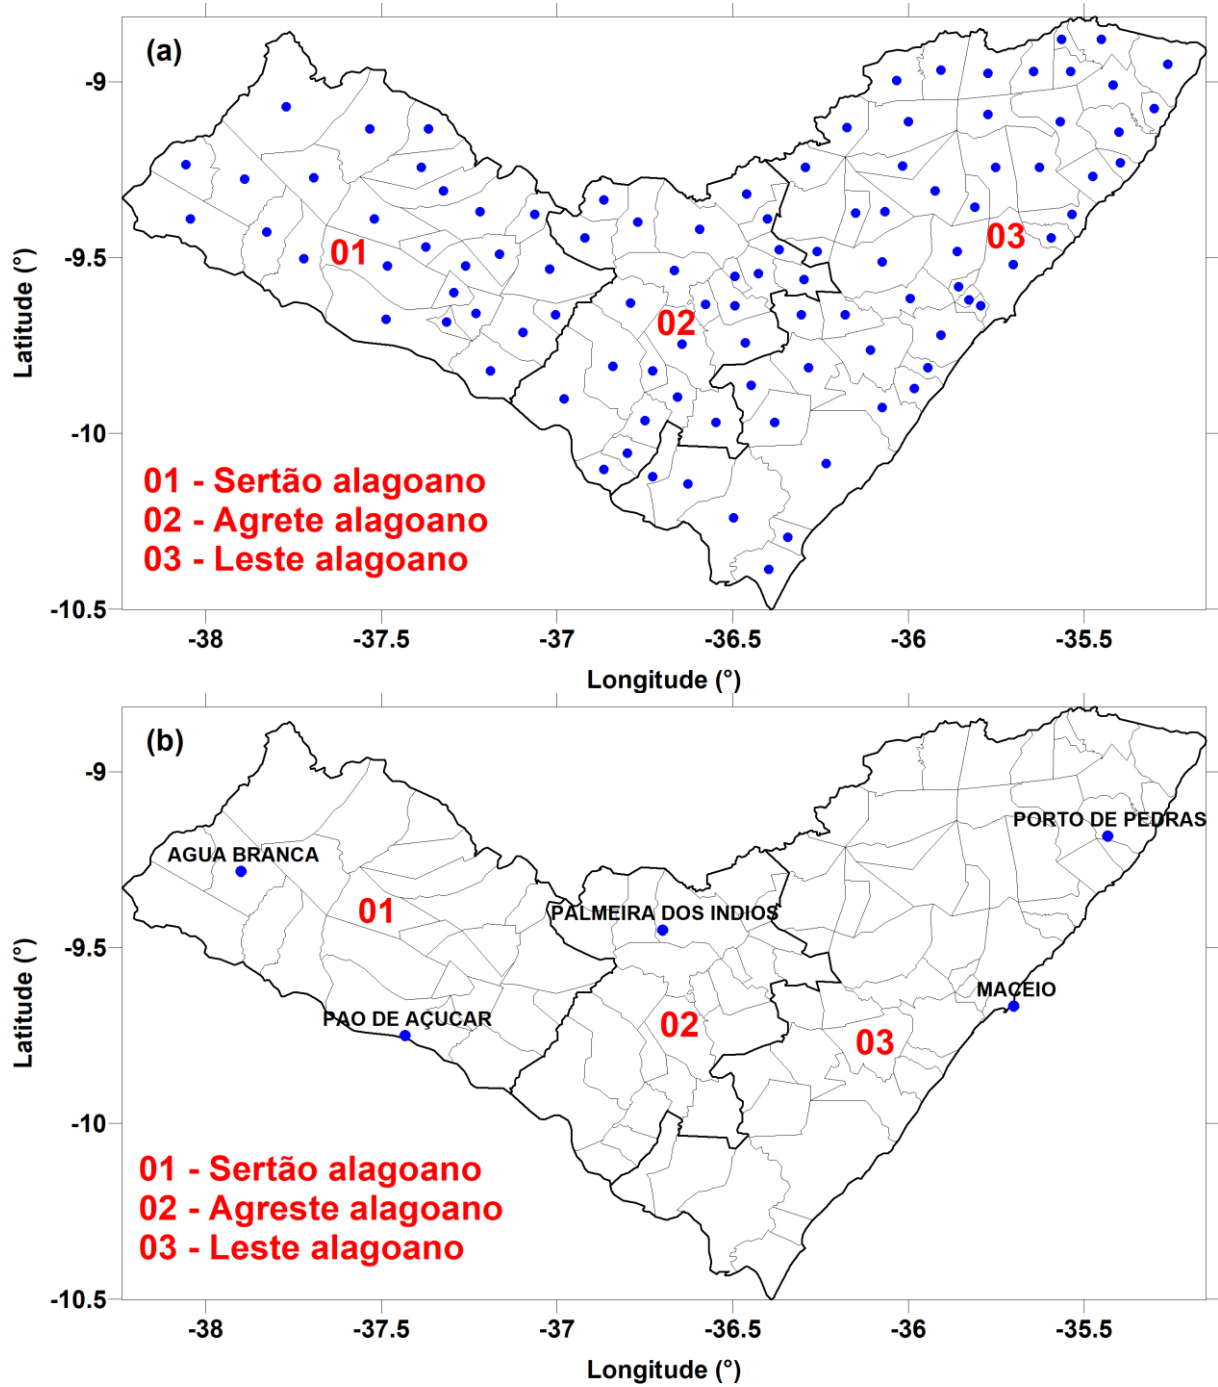
Os dados de produtividade observada do milho para o Estado de Alagoas são disponibilizados pelo Instituto Brasileiro de Geografia e Estatística (IBGE), através de seu Sistema IBGE de Recuperação Automática (SIDRA). Pelo SIDRA é possível obter dados da produtividade média da produção, em quilogramas por hectare, das lavouras temporárias de milho a partir do ano de 1974 com dados mensais. Os dados de produtividade fornecidos pelo IBGE não informam o ciclo da cultura nem a variedade plantada, desta forma, utilizou-se esta informação como sendo o rendimento obtido para determinado município considerando um ciclo médio para o milho de 120 dias.

Foram utilizadas três das fontes de dados para diferentes finalidades. Para o zoneamento da melhor época de semeadura e determinação dos níveis médios de produtividade do milho em todo o Estado de Alagoas, foram extraídas séries temporais de precipitação e evapotranspiração diárias para cada município do Estado a partir da análise gradeada disponibilizada por XAVIER ET AL (2016), relativas ao período 1980-2015 (Figura 2a).

As séries temporais foram extraídas para cada município de Alagoas utilizando o método de interpolação bilinear simples (LIU ET AL, 2015). Esse método calcula um valor da variável em um ponto específico da grade (centroide do município), atribuindo pesos característicos a cada um dos quatro pontos da grade em relação à coordenada geográfica do ponto do centroide de interesse, com um peso maior quanto mais próximo do centroide estiver o respectivo ponto da grade (ROCHA JÚNIOR ET AL, 2019).

Para calibração, verificação e geração de cenários futuros de mudanças climáticas, foram utilizados dados de precipitação, temperaturas máximas e mínimas das cinco estações meteorológicas convencionais do Instituto Nacional de Meteorologia (INMET) em Alagoas, no período de 1979 a 2010, localizadas especificamente nos municípios de Água Branca e Pão de Açúcar no sertão, Palmeira dos Índios no agreste, e Maceió e Porto de Pedras no leste do Estado (Figura 2b). Os dados destas estações também serviram de base para a calibração do modelo agrometeorológico apresentado na próxima seção.

**Figura 2.** (a) Centroides dos municípios em que foram extraídas séries temporais de PREC e ETP da análise gradeada (Fonte: XAVIER ET AL, 2016); (b) Distribuição espacial das estações convencionais do INMET nas diferentes mesorregiões de Alagoas.





### 3.2 MODELO AGROMETEOROLÓGICO DE PENALIZAÇÃO POR DEFICIÊNCIA HÍDRICA

Foi utilizado o modelo proposto por DOORENBOS e KASSAN (1979), que estabelece a penalização do rendimento agrícola a partir da deficiência hídrica no decorrer das fases fenológicas da cultura. Esse modelo foi escolhido, pois a maior parte das perdas agrícolas no Nordeste brasileiro se dá por secas e/ou estiagens prolongadas, não apenas no semiárido (ALVALÁ ET AL, 2017).

Este modelo é composto por dois módulos: um que estima a produtividade potencial da safra ou produtividade máxima, e outra que estima o decréscimo do potencial de produtividade em função do déficit hídrico.

O passo de tempo do modelo é decendial e as únicas entradas são a precipitação e a evapotranspiração potencial da cultura (ETPc). A Evapotranspiração Real da Cultura (ETRc) e o coeficiente de penalização por déficit hídrico (ky), são provenientes do balanço hídrico para o ciclo da cultura, mostrados na equação 1.

$$Yd = \left(1 - \frac{ETRc}{ETPc}\right) \times ky \times 100 \quad (1)$$

As de equações 2 a 7 mostram os estágios anteriores necessários para que se chegue aos resultados obtidos pela equação 1. Como já comentado, nestes cálculos assumiu-se um ciclo da cultura de 120 dias. Este ciclo contém os coeficientes da cultura (kc) e de penalização hídrica (ky), com valores diários. O cálculo da evapotranspiração da cultura (ETC) depende de um valor para o kc, e a (ETRc) depende de um coeficiente de umidade para o solo, o ks, calculado conforme o manual de irrigação de SALASSIER ET AL (2008), abaixo.

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

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

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

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

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

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

em que: ETP = evapotranspiração; ETPc = evapotranspiração da cultura; CAD = capacidade de campo; ARM = armazenamento de água no solo; ARMc = armazenamento crítico (a partir do qual a planta perde produtividade); ARMant = armazenamento anterior; p = fator de disponibilidade, tabelado pela *FoodandAgricultureOrganizationofthe United Nations* (FAO); ks = coeficiente de umidade; kc = coeficiente de cultura; kmax = máximo coeficiente de cultura. O ARM nunca pode ser maior do que a CAD.

A CAD, definida como a quantidade máxima de água que o solo pode armazenar na profundidade explorada pelo sistema radicular da planta, foi obtida do aplicativo “sisdagro” do site do INMET (<http://sisdagro.inmet.gov.br/sisdagro/app/monitoramento/bhcirrigado>), para solos de textura média entre as classificações arenosa e argilosa, para as localidades presentes de Alagoas presentes no *software*, todas com CAD igual a 60 (média de 43,2 para solos arenosos e 76,8 para solos argilosos em Alagoas).

### 3.3. CALIBRAÇÃO DO MODELO AGROMETEORLÓGICO

O modelo agrometeorológico proposto foi calibrado para o período 2000-2010, com dados observados da produtividade do milho nos municípios onde existem estações meteorológicas convencionais do, em kg/ha, com exceção apenas de Maceió, que não possui histórico de produção do milho, de acordo com a metodologia proposta por MONTEIRO ET AL (2013; 2017).

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

$$\Delta p: PMT = TPA \times \Delta p \quad (8)$$

Desta forma,  $\Delta p$  é ajustado de uma regressão linear sem tendência e consiste em um dos parâmetros calibrados no modelo, de acordo com o método indicado a seguir. Os valores dos coeficientes de cultura ( $k_c$ ) e de déficit hídrico ( $k_y$ ), apresentados por DOOREMBOS e KASSAM (2000) para o milho, de acordo com suas fases fenológicas, são adaptados para a escala diária, facilitando sua posterior obtenção para a escala decenal.

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

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

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

$$\frac{PR}{PMT} = \left[ 1 - \left( \frac{ETR_c}{ETP_c} \right) \right] \times k_y \times k_y^* \times 100 \quad (10)$$

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

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

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

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

No modelo da Equação 9, a ETRc é calculada pelo balanço hídrico sequencial, onde são computadas as mudanças diárias na umidade do solo, de acordo com o método de THORNTHWAITE (1948).

### 3.3.1. Processamento do *Downscaling*

O *downscaling* estatístico (SD) usa informações em larga escala (preditor) para construir relações com a variável climática local (preditando). MARAUN ET AL (2010) descreveram de forma simplificada como se dá esta interação entre o preditor (X) e o valor esperado (E) do predictando (Y), incluindo um vetor ( $\beta$ ) de parâmetros desconhecidos (Eq. 12).

$$E(Y|X) = f(X, \beta) \quad (12)$$

Os principais critérios para que variáveis de larga escala sejam qualificadas como preditores são que: (1) sejam simuladas de forma confiável pelos MCGs; (2) estejam prontamente disponíveis em arquivos de saída do MCG; (3) se correlacionem fortemente com as variáveis de superfície de interesse e (4) transportem informações sobre mudanças climáticas (WILBY ET AL 2013). A principal ressalva do *downscaling* estatístico é a suposição de que as relações derivadas com dados de superfície observados também são válidas em um clima perturbado no futuro, que é uma suposição que não pode ser testada em princípio. No entanto, os baixos custos computacionais e a implementação relativamente direta o tornam um candidato útil para estudos de impacto das mudanças climáticas (GOODESS ET AL 2010).

Para diminuir as incertezas associadas, alguns processos são imprescindíveis para aumentar a confiabilidade no MDE escolhido e nos dados sintéticos gerados para o horizonte futuro e suas aplicações. A primeira é a escolha dos preditores e os respectivos processos de calibração e validação em relação a um clima observado. A segunda é um conhecimento básico dos MCGs utilizados e respectivos cenários de mudanças (BRANDS ET AL, 2011A; BRANDS ET AL, 2012; GUTIERREZ ET AL, 2013; KAZMI ET AL, 2015; ALI ET AL, 2019; SADDIQUE ET AL, 2019).

Para os cenários RCP4.5 e 8.5, foram utilizados sete MCGs do Coupled Model Intercomparison Project Phase 5 (CMIP5): CANESM2, do Canadian Centre for Climate Modelling and Analysis (Canadá); CNRM-CM5, do Centre National de Recherches Météorologiques (França); GFDL-ESM2M do National Oceanic and Atmospheric Administration (Estados Unidos); IPSL-CM5A-MR do Institut Pierre Simon Laplace

(França); MIROC-SEM, desenvolvido pela Universidade de Tóquio e parceiros (Japão); MPI-ESM-MR do Max Planck Institut fur Meteorologie (Alemanha), e o NORESM1-M do Norwegian Climate Center's Earth System Model (Noruega). Breve descrição de cada MCG é fornecida a seguir.

- **CANESM2** é a segunda geração do modelo canadense do sistema terrestre CANESM, é composto de um modelo físico acoplado oceano-atmosfera - CanCM4, um modelo de carbono terrestre - CTEM, e oceânico - CMOC. Os componentes terrestres e oceânicos do ciclo do carbono funcionam de duas formas, na primeira emissão antropogênicas de CO<sub>2</sub> são especificadas de forma interativa e o modelo é capaz de simular a evolução do conteúdo atmosférico de CO<sub>2</sub>. Na segunda, os fluxos de CO<sub>2</sub> terra-atmosfera e oceano-atmosfera permanecem determinados e os resultados dos modelos podem ser usados para diagnosticar emissões antropogênicas de CO<sub>2</sub> (ZAHARIEV ET AL, 2008; ARORA ET AL, 2009; ARORA e BOER, 2010).

- **CNRM-CM5** é uma evolução do modelo do sistema terrestre CNRM-CM3, projetado para executar simulações climáticas. Composto por vários modelos independentes e acoplados. O modelo atmosférico é o ARPEGE-Climate, NEMO é o modelo oceânico, GELATO o modelo de gelo marinho, o modelo de fluxos terrestres é o SURFEX, e o modelo de carga e descarga de água entre rios e oceanos é o TRIP. O CNRM-CM5 é capaz de simular o clima atual e sua variabilidade em escalas de tempo que variam de meses a séculos, simulando o clima futuro a depender dos cenários de gases de efeito estufa. Estão incorporados no modelo os efeitos dos aerossóis atmosféricos, as variações de irradiância solar, e o impacto de grandes erupções vulcânicas (SALAS-MELIÁ, 2002; SALAS-MELIÁ ET AL, 2005; VOLDOIRE ET AL, 2011).

- **GFDL-ESM2M** é o modelo desenvolvido pelo *Geophysical Fluid Dynamics Laboratory do National Oceanic and Atmospheric Administration*, baseado em modelos de circulação atmosférica associados a modelos oceânicos, com representações da dinâmica da terra, gelo marinho e icebergs, e biogeoquímica interativa, incluindo o ciclo do carbono. O módulo atmosférico inclui as características físicas dos aerossóis naturais e antropogênicos, física de nuvens e precipitação. O componente terrestre inclui o balanço hídrico. O componente oceânico inclui processos de ondas, correntes, dinâmica do gelo marinho, transporte de água doce em icebergs, biogeoquímica e ecologia marinha. Cenários de emissões são usados para avaliar o impacto de uma série de atividades humanas na atmosfera, hidrosfera, criosfera,

superfície terrestre e biosfera (DUNNE ET AL, 2012; TAYLOR ET AL, 2012; DUNNE ET AL, 2013).

- **IPSL-CM5A-MR** é desenvolvido pelo *Institut Pierre-Simon-Laplace* (IPSL), um consórcio de laboratórios de pesquisa dedicados ao estudo do sistema climático e do ambiente global. Inclui 5 modelos que representam o clima do sistema terrestre e seu ciclo de carbono: LMDZ (Atmosfera), NEMO (Oceano, biogeoquímica oceânica e gelo marinho), ORCHIDEE (superfícies e vegetação continental) e INCA (química atmosférica). O sistema que acopla todos os módulos é o OASIS. O IPSL-CM5A-MR é a versão de média resolução do modelo do sistema terrestre IPSL-CM5A. A resolução é de  $1,25^{\circ} \times 2,5^{\circ}$  com 39 níveis verticais para a atmosfera e 31 níveis verticais para o oceano. Esta é uma versão para o CMIP5, aprimorada do IPSL-CM4 usado para o CMIP3 (DUFRESNE ET AL, 2013).

- **MIROC-ESM** é baseado no MCG MIROC, desenvolvido na Universidade de Tóquio. Envolve o modelo de circulação geral da atmosfera MIROC-AGCM2010, que inclui o componente de aerossóis SPRINTARS5.00, um MCG oceânico com componente do gelo marinho COCO3.4 e um modelo de superfície terrestre MATSIRO. O MIROC-ESM contém um módulo de química atmosférica, um do ecossistema oceânico e terrestre que trata a vegetação de forma dinâmica. O MIROC-AGCM possui um núcleo dinâmico espectral e utiliza um esquema semi-lagrangiano para a advecção de fluxo. Seu truncamento triangular tem número total de 42 ondas horizontais, com grade de aproximadamente 2,8125 graus de latitude-longitude. Usa o sistema de coordenadas verticais sigma com 80 camadas (NOZAWA ET AL, 2007; WATANABE ET AL, 2011).

- **MPI-ESM-MR** é uma versão de média resolução do modelo do sistema terrestre MPI-ESM desenvolvido pelo Instituto Max-Planck. Possui módulos atmosféricos (ECHAM6), oceânicos (MPI-OM), da superfície terrestre (JBASCH) e para a biogeoquímica do oceano. Estes componentes são acoplados através das trocas de energia, momento, água e gases como o dióxido de carbono. Foi desenvolvido com base nos modelos antecessores ECHAM5-MPI-OM e suas versões COSMO. O ECHAM5-MPI-OM foi usado nas simulações do CMIP3. Possui um módulo de aerossóis e química (HAMMOZ) e é utilizado em mais de 45 instituições em todo o mundo (JUNGCLAUS ET AL, 2013; GIORGETTA ET AL, 2013; MULLER ET AL, 2018).

- **NORESMI-M** é a versão intermediária do modelo NORESM, com resolução horizontal de  $2^{\circ}$  para o módulo atmosférico e de  $1^{\circ}$  para o módulo oceânico e de gelo. Esta versão é

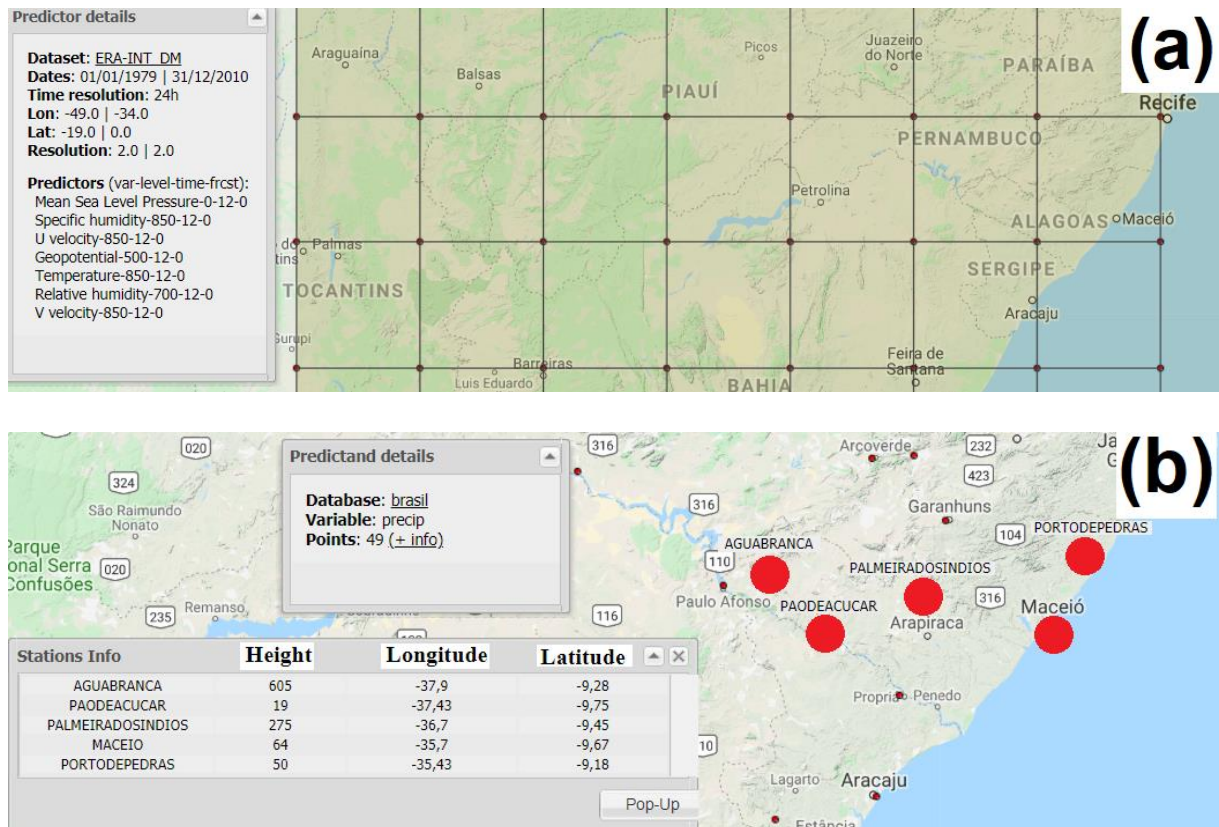
utilizada para fornecer resultados para o CMIP5, possui um módulo para simular o ciclo do carbono e é baseado no modelo CCSM4 operado pelo NCAR, modelo oceânico MICOM, e modelo atmosférico estendido com cálculo on-line de aerossóis e seus efeitos diretos e indiretos em nuvens quentes (BENTSEN ET AL, 2012; IVERSEN ET AL, 2013, GUO ET AL, 2019).

### **3.3.1.1. Preditores e Preditandos**

As variáveis predictoras utilizadas neste estudo foram dados de larga escala em ponto de grade com resolução espacial de  $2 \times 2^\circ$  da pressão média corrigida ao nível do mar (PMNM) e altura geopotencial ( $\Phi$ ) a 500 mbar, umidade relativa (UR) em 700 mbar, ventos meridionais e zonais (V e U) em 850mbar, temperatura (T) em 850mbar e umidade específica (q) em 850mbar, provenientes de dados diários de reanálises do projeto ERA-Interim (Figura 3a). Para mais detalhes desta reanálise sugere-se a leitura de DEE ET AL (2011), que descreve o modelo de previsão, o método de assimilação de dados e os conjuntos de dados de entrada observados usados para produzi-la, e que discute ainda o desempenho do sistema, além de fornecer evidências das melhorias em relação a versão anterior desta reanálise, a ERA-40.

O MDE empregado para relacionar os dados das reanálises às variáveis de superfície foi o método de análogos. Nesse caso, os resultados da reanálise para um período representativo do passado (normalmente 30 anos) são usados como preditores, enquanto observações históricas simultâneas na escala local são usadas como predictandos para o treinamento do modelo. Uma vez que a configuração do modelo ideal é encontrada usando esses dados (quase) observados (BRANDS ET AL, 2012), o MDE poderá ser aplicado às saídas de diferentes execuções de MCGs para obter projeções futuras em diferentes cenários de mudanças climáticas, e ter estes resultados regionalizados à escala local de estações meteorológicas, aqui aplicadas às séries temporais de precipitação e temperaturas máximas e mínimas das estações do INMET localizadas no Estado de Alagoas (Figura 3b).

**Figura 3. (a)** Imagem da grade sobre o parte da região Nordeste e Estado de Alagoas utilizada para estabelecer relações preditor (reanálises) - preditando (observações de superfície); e **(b)** distribuição espacial das estações convencionais do INMET em Alagoas.



### 3.3.1.2. Calibração e Validação

O método dos análogos foi validado após o período de treinamento e testes. O período histórico comum para preditores (reanálises) e preditandos (observações), é dividido em treinamento (75% dos dados) e testes (25% dos dados), para o período de 1979 a 2010. A calibração do MDE utiliza os dados de treinamento para verificar a similaridade climática entre as observações e simulações, ou seja, se o clima passado foi bem representado pelos preditores oriundos da reanálise, relativa ao período de 1979 a 2000 (75% dos dados).

A fase de validação consiste em avaliar métricas estatísticas de natureza descritiva, medidas de acurácia e de similaridade das distribuições dos dados, para o período 2001-2010 (25% dos dados), descritas a seguir. Vale ressaltar que todas estas métricas de validação foram obtidas para o acúmulo de tempo decenal, ou seja, para a precipitação acumulada em



10 dias e para as temperaturas máximas e mínimas em 10 dias. Utilizou-se este período de acumulação dos dados diários para compactuar com o passo de tempo do modelo agrometeorológico, que é decendial.

• **Estatística descritiva**

Média: É a média aritmética decendial. Mede a tendência central da amostra. É calculada pela soma de todos os pontos dos dados ( $x_i$ ,  $i = 1, \dots, n$ ), dividido pelo tamanho  $N$  da amostra.

$$M = \frac{1}{N} \sum_{i=1}^N x_i \quad (13)$$

Desvio Padrão: Mostra o quão grande pode ser, ou não, a variação em torno da média, definida como a raiz quadrada da variância.

$$s = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (14)$$

• **Medidas de acurácia**

Para verificação da qualidade dasimulação do clima observado, foi utilizado o coeficiente de correlação de Pearson ( $r$ ) para medir o grau de concordância entre as simulações e as séries históricas. O coeficiente de correlação de Pearson entre duas variáveis (observações( $o$ ) e simulações( $s$ )) é definida como a covariância das duas variáveis ( $Cov(o, s)$ ) dividida pelo produto de seus desvios-padrão.

$$r_{o,p} = \frac{Cov(o, s)}{\sigma_o} = \frac{\sum_{i=1}^N (o_i - \bar{o})(s_i - \bar{s})}{\sqrt{\sum_{i=1}^N (o_i - \bar{o})} \sqrt{\sum_{i=1}^N (s_i - \bar{s})}} \quad (15)$$

Para garantir se um valor de  $r$  realmente exprime concordância entre observações estimulações, aplicou-se o teste paramétrico *t-Student*, que consiste em formular uma hipótese nula e conseqüentemente uma hipótese alternativa, calcular o valor conforme a fórmula apropriada e aplicá-lo à função densidade de probabilidade da distribuição  $t$  medindo o tamanho da amostra. Uma premissa para o uso do teste é que o tamanho da amostra,  $N$ , da

qual se obtém o valor do coeficiente de correlação,  $r$ , seja igual ou superior a 1, então o valor de  $t$  é dado por:

$$t = \frac{r}{\sqrt{(1-r^2)/(N-2)}} \quad (16)$$

A equação (16) é uma distribuição para  $t$  com  $N-2$  graus de liberdade. A aplicação desta fórmula para qualquer valor de  $r$  e de  $N$  vai testar a hipótese nula de que o valor observado vem de uma população em que não existe correlação significativa entre os dados. Uma vez obtido o valor de  $t$ , pode-se extrair o coeficiente de correlação crítico ( $r_c$ ), que é um valor para a qual se aceita ou não a hipótese estatística que existe correlação entre os dados simulados e observados.  $r_c$  é dado por:

$$r_c = \sqrt{\frac{t^2}{(N-2) + t^2}} \quad (17)$$

#### • Similaridade das distribuições

A análise da semelhança das distribuições descreve a qualidade de uma simulação/previsão, particularmente em escalas temporais onde não se pode averiguar a correspondência serial entre previsões e simulações, exatamente como no caso de projeções de mudanças climáticas. Desta forma, estes índices medem a similaridade em termos climatológicos. A similaridade da distribuição deve ser cuidadosamente examinada, especialmente para estudos de mudanças climáticas. Aqui, dois índices serão avaliados:

**RV:** Razão de Variâncias. Esta pontuação mede a relação entre as variações das previsões e das observações. Varia entre  $[0, \infty)$ . Pontuação perfeita: 1.

$$RV = \frac{s_p^2}{s_0^2} \quad (18)$$

**PDFscore:** O *PDFscore* mede a sobreposição entre as funções de densidade de probabilidade empíricas observadas e previstas. Varia no intervalo  $[0,1]$ . Pontuação perfeita: 1. Este índice é calculado como em Perkins e McAneney (2007):

$$PDFscore = \sum_{i=1}^{200} (PDF_{pi} - PDF_{oi}) \quad (19)$$

Onde  $PDF_{pi}$  é a densidade de probabilidade das previsões e o  $PDF_{oi}$  é a densidade de probabilidade das observações, para 200 classes definidas em toda a gama de observações e previsões. A densidade de probabilidade para cada classe é estimada por um filtro de Kernel em uma abordagem não paramétrica para encaixe das densidades. Todas as densidades são comparadas para cada classe, por um parâmetro de largura otimizado para distribuições normais.

O  $PDF_{score}$  é pouco sensível a falhas nas caudas das distribuições. No caso da precipitação diária, devido à alta densidade de probabilidade de classes localizadas próximas a zero, este índice é calculado apenas para a parte contínua das distribuições, considerando-se exclusivamente os dias com chuva observada e prevista.

## 4. RESULTADOS E DISCUSSÕES

### 4.1 CALIBRAÇÃO DO MODELO AGROMETEOROLÓGICO

A calibração do modelo agrometeorológico foi realizada para quatro municípios (Água Branca e Pão de Açúcar no sertão alagoano, Palmeira dos Índios no agreste alagoano e Porto de Pedras no leste alagoano) com auxílio das estações meteorológicas do INMET. Nesses municípios, as produtividades médias anual observadas com os dados do IBGE entre 2000 e 2010 foram de 368 kg/ha em Água Branca, 448 kg/ha em Pão de Açúcar, 522 kg/ha em Palmeira dos Índios e 629 kg/ha em Porto de Pedras. Nota-se que a produtividade média é inferior a 1000 kg/ha, o que caracteriza um cultivo como de baixa produtividade no Estado de Alagoas (CONAB, 2019).

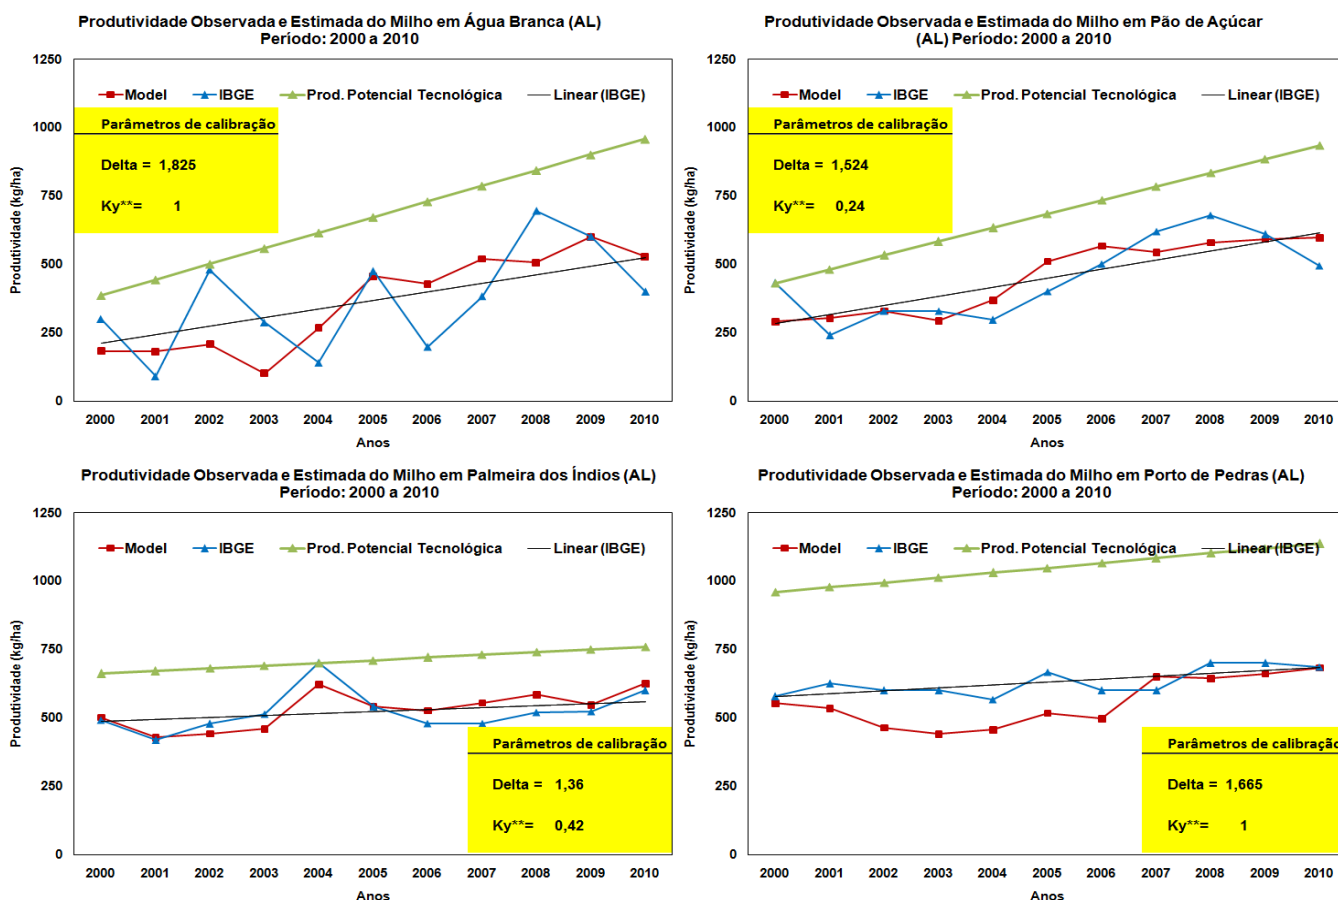
Além disso, observa-se um aumento da produtividade do milho da mesorregião do Sertão para a do Leste alagoano. Essa variabilidade reflete as condições climáticas do Estado, comum gradiente de precipitação zonal do litoral (maior acumulação anual) ao alto sertão (menor acumulação anual). No caso do milho em Alagoas, predomina a agricultura familiar de subsistência, em regime de sequeiro (CONAB, 2019).

Nesta perspectiva, foram calculados o coeficiente de rendimento máximo tecnológico ( $\Delta p$ ) e o fator de déficit hídrico ajustado ( $ky^*$ ) para cada município, durante o processo de calibração do modelo de produtividade. Estes parâmetros permitiram simular o rendimento com maior precisão em cada município.

Na Figura 4 são apresentados os gráficos de produtividade observados e simulados com o modelo agrometeorológico para cada ano dos municípios selecionados. Observa-se que Palmeira dos Índios, Porto de Pedras e Pão de Açúcar apresentaram melhores correlações entre os dados observados e simulados pelo modelo, 0,78, 0,69 e 0,81 respectivamente, e erros relativos de 7,4%, 13,3% e 16%. No município de Água Branca o erro relativo foi superior a 30% e a correlação igual a 0,59.

Tais resultados demonstram a habilidade do modelo em simular as observações. Percebe-se ainda na Figura 4 a tendência positiva da produtividade na reta de mínimos quadrados dos dados do IBGE, e o potencial de rendimento crescente atingível representado pela linha da tendência da produtividade potencial tecnológica.

**Figura 4.** Produtividades observadas e simuladas do milho nas cidades Água Branca, Pão de Açúcar, Palmeira dos Índios e Porto de Pedras.



## 4.2 ZONEAMENTO DA MELHOR ÉPOCA DE SEMEADURA

Os resultados exibidos no tópico anterior demonstram a confiança em se utilizar o modelo, e os resultados obtidos levaram em conta as datas de plantio preconizadas pelo Governo Federal em sua Portaria de N° 167 de 2 de outubro de 2013, publicado pela Secretaria de Política Agrícola do Ministério da Agricultura Pecuária e Abastecimento (MAPA), que estabeleceu o zoneamento agrícola do risco climático para a cultura do milho no Estado de Alagoas, e o respectivo calendário agrícola da semeadura da cultura, onde se recomenda três decêndios preferenciais de plantio, 20/04, 20/05 e 20/06.

No entanto, buscou-se examinar se estes seriam realmente os melhores decêndios para a semeadura, ou seja, as que climaticamente, levam a uma maior produtividade. Para tanto, a partir da base de dados disponibilizada por XAVIER ET AL (2016), para cada município foi obtida as séries temporais decendiais de precipitação e ETP relativas ao período 1980-2015, e para cada decêndio do ano foram simulados os rendimentos, permitindo obter médias anuais

da produtividade em cada município e desta forma estabelecer o período em decêndios mais apto a semeadura.

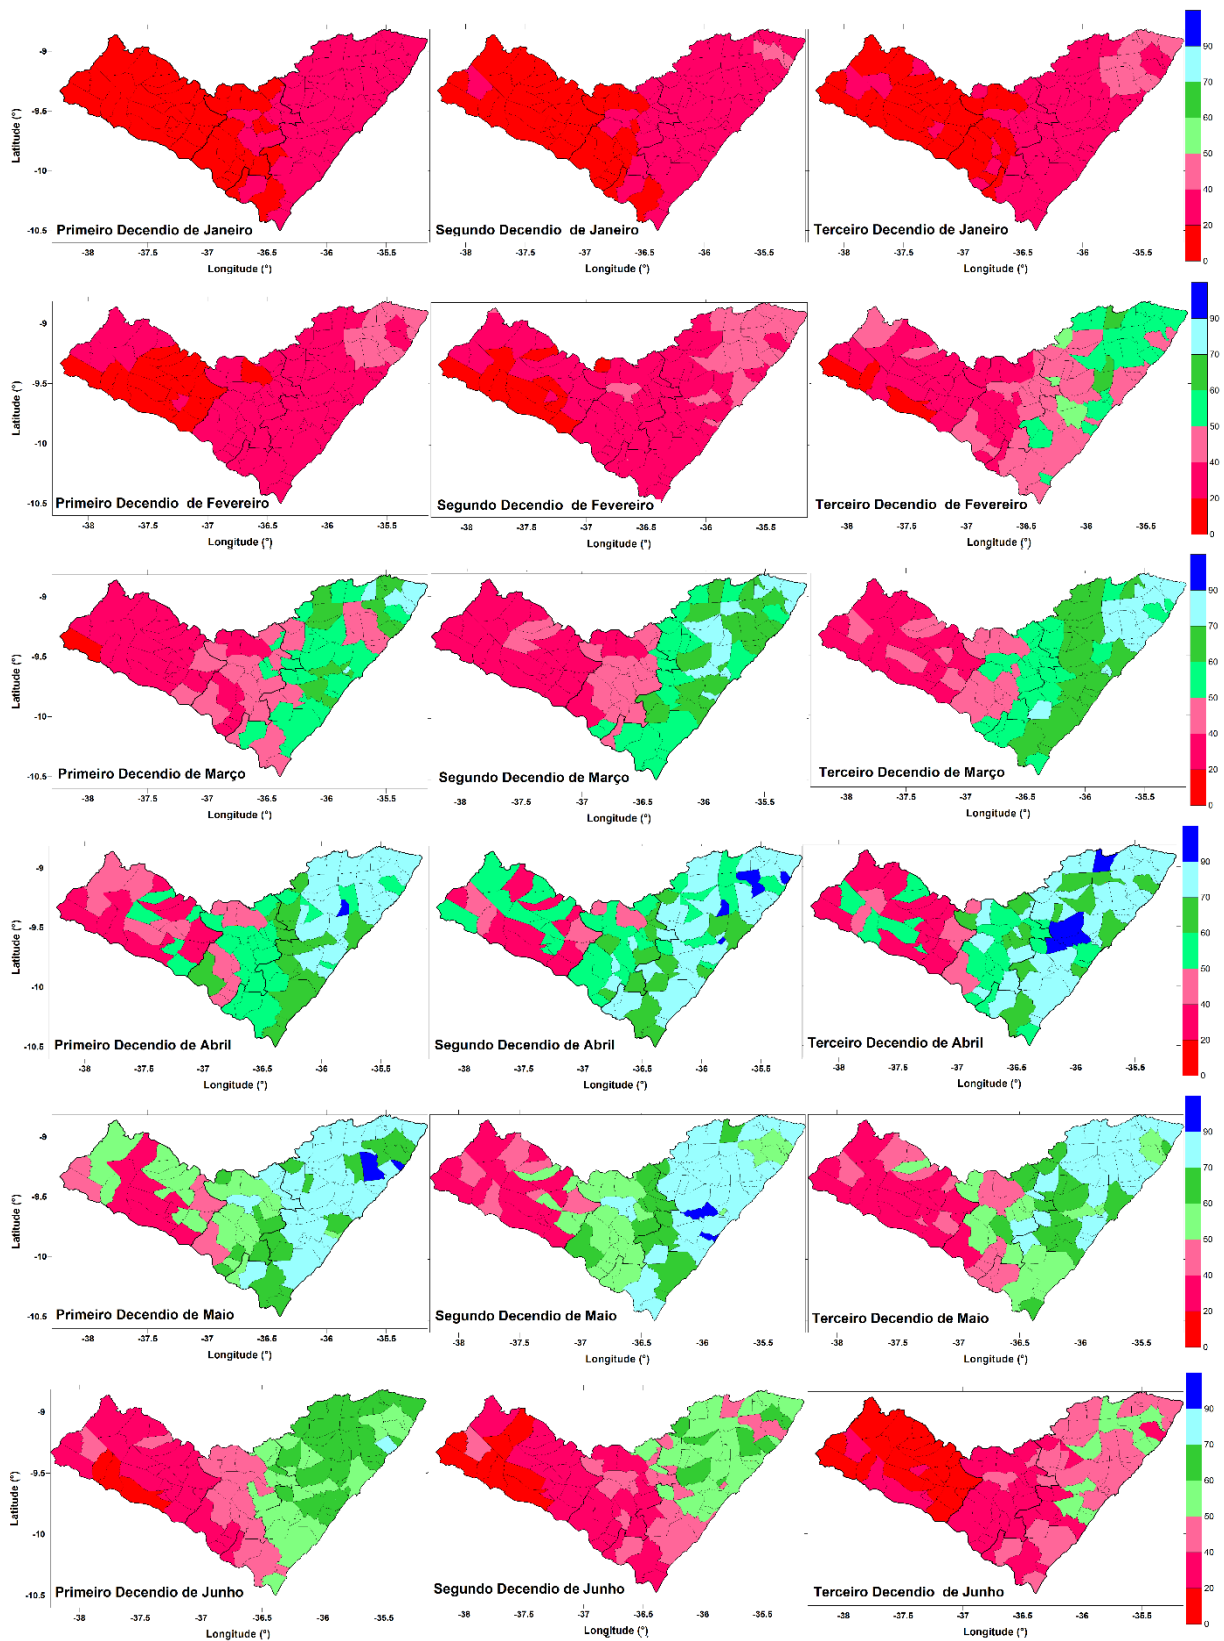
Tal metodologia reversa de estimativa das produtividades simulando com modelos agrometeorológicos esta variável para um período passado conhecido foi utilizada por PAIXÃO ET AL (2014), também para o milho em condições de sequeiro, para a determinação de uma melhor janela de semeadura a fim de reduzir os impactos naturais da variabilidade climática anual e interanual na produtividade. O modelo utilizado foi o CSM-Ceres-Maize, e o local analisado foi o estado Minas Gerais. Como resultados foram visto que este tipo de modelagem traz vantagens em relação às metodologias adotadas pelo MAPA, permitindo integrar fatores não considerados no zoneamento tradicional, além da possibilidade de determinar o rendimento médio esperado e a sua amplitude.

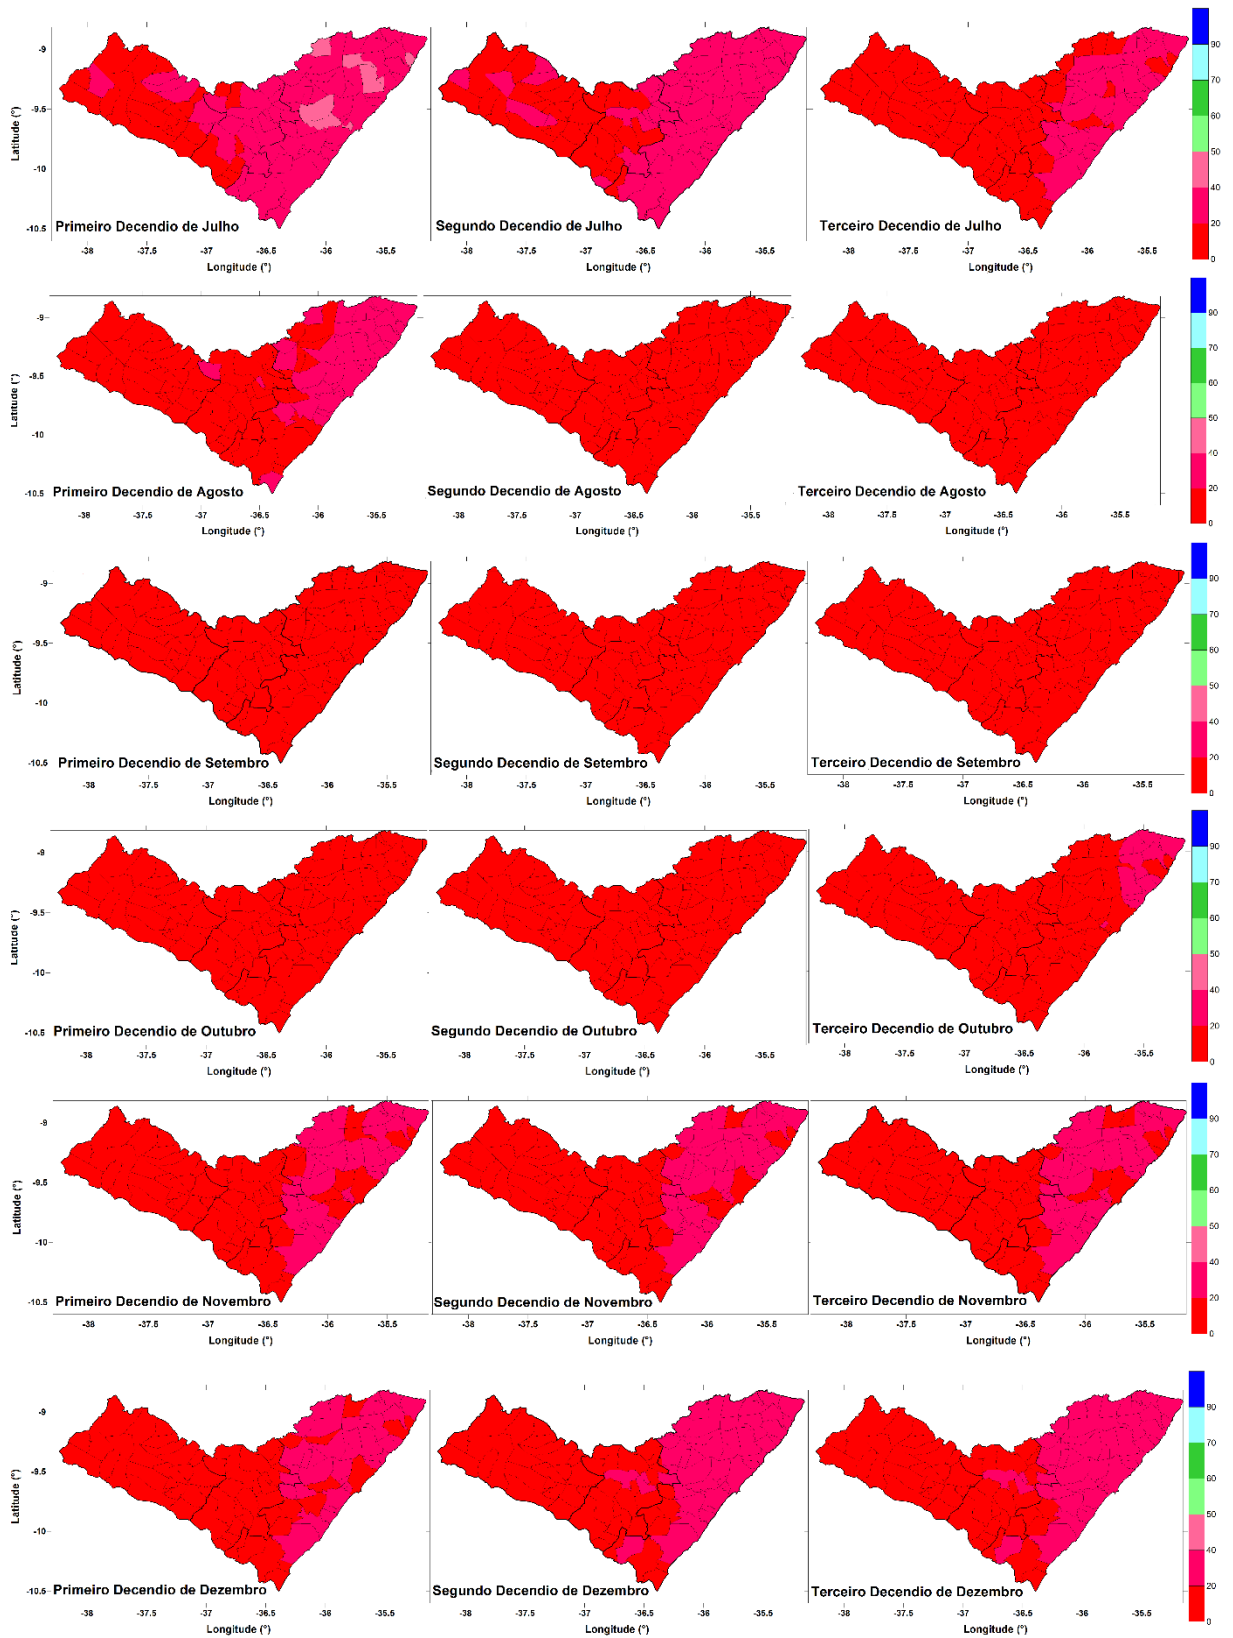
MONTEIRO ET AL (2013), aplicaram o mesmo modelo agrometeorológico para avaliar a perda de produtividade por deficiência hídrica em diferentes localidades brasileiras, e concluíram que, quando o modelo indicava perda relativa superior 50%, em mais de 90% as perdas em campo foram comprovadas por laudos técnico do IBGE, preparados por técnicos agrícolas *in loco*. De acordo com este resultado, utilizou-se nos resultados da Figura 5 uma escala inversa, mostrando a variação de produtividade percentual atingível de 0 a 100%, ou seja, as cores em vermelho indicam os menores valores de produtividade relativa e valores acima de 60%, tons de verde e azul, os que indicam maior probabilidade de que se alcance uma boa produtividade.

A primeira percepção desses resultados refere-se aos períodos desfavoráveis ao cultivo, que se daria caso a semeadura ocorra em todos os decêndios de janeiro até o segundo decêndio de fevereiro, quando se iniciam condições um pouco mais favoráveis à produtividade no norte da mesorregião leste no terceiro decêndio deste mês, e novamente desfavoráveis em todo o Estado a partir de julho até dezembro.

A partir do primeiro decêndio de março, condições favoráveis para o cultivo se fortalecem no leste, avançando gradativamente para o agreste e sertão alagoano, com destaque entre o primeiro decêndio de abril ao primeiro decêndio de maio. Percebe-se visualmente que a janela de semeadura mais favorável à obtenção de maiores produtividades é mais larga na mesorregião leste, e menores no agreste e sertão, respectivamente.

**Figura 5** Produtividade relativa percentual média do milho para o primeiro, segundo e terceiro decêndios de janeiro a dezembro, em sequência.





Como se pôde observar, o mapeamento traz boa noção das melhores janelas de oportunidades para a semeadura do milho nas diferentes mesorregiões. Mas ainda torna-se



tarefa difícil estabelecer a época de plantio para uma dada mesorregião, dada a variabilidade entre municípios como ocorre no do sertão alagoano.

Para facilitar este processo de determinação de um calendário ótimo de semeadura em cada mesorregião, foi considerado como favoráveis os decêndios do ano que conseguem superar em, ao menos, 50% a produtividade relativa. Para tanto, em cada mesorregião, os resultados foram compilados a partir da média dos dados das cidades que as compõem. No caso do sertão, o resultado da produtividade potencial do milho foi obtido dos valores médios de 28 municípios, para o agreste de 21 municípios e para o leste alagoano de 53 municípios totalizando os 102 municípios que compõe o estado.

Com esses resultados, a Figura 6 permite concluir que o sertão é a mesorregião mais vulnerável às perdas agrícolas, com a menor janela de favorabilidade à semeadura, entre o primeiro e terceiro decêndio de abril, e as menores produtividades relativas em torno de 55% (Figura 6a).

O agreste alagoano apresenta alta vulnerabilidade às perdas, com produtividades relativas em torno de 55% a 60%, porém com maior janela de favorabilidade à semeadura, entre o terceiro decêndio de março e o terceiro decêndio de maio (Figura 6b). Com isso pode-se concluir que essa zona de transição tem um potencial considerável sendo possível desenvolver técnicas para diminuir a carência de água realizando inovações nos processos de manutenção hídrica que podem colaborar para o alongamento dessa janela.

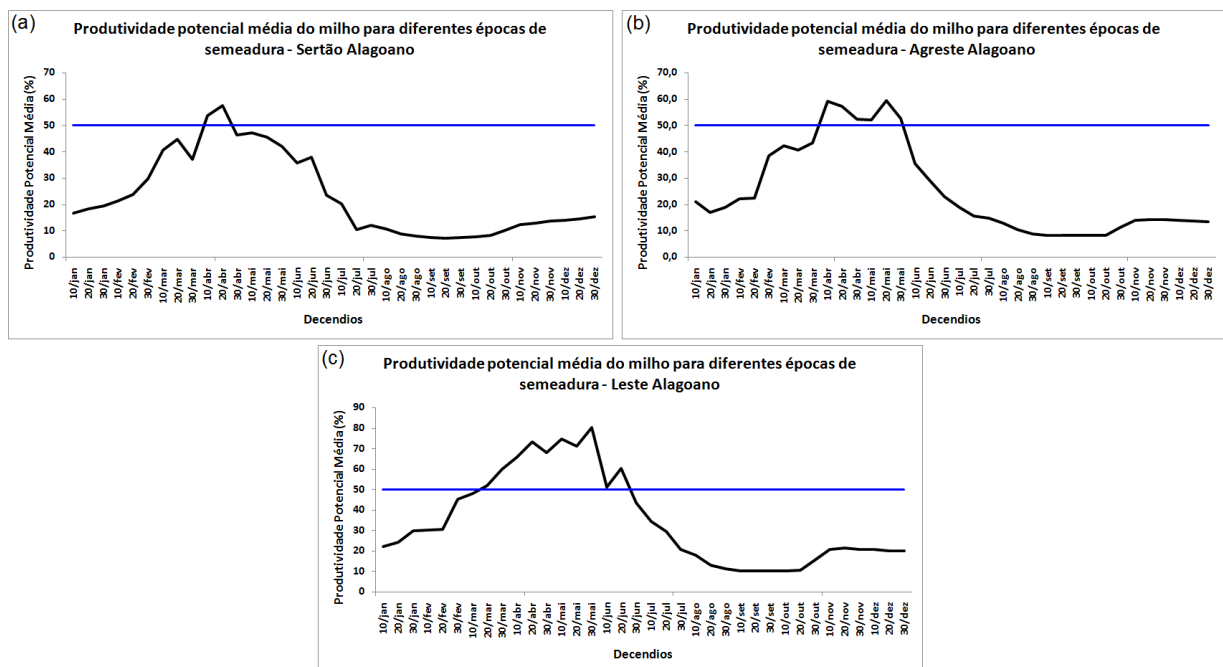
O leste alagoano possui a maior janela para o plantio, entre o primeiro decêndio de março e o segundo decêndio de junho, e as maiores produtividades relativas médias podendo atingir o patamar de 80% (Figura 6c). Além disso, essa faixa tem o benefício geográfico de sua localização que por sua vez possui maiores índices pluviométricos, podendo ser mais explorado o seu potencial agrícola utilizando a mecanização no processo colaborando com a melhora nos índices socioeconômico da região.

Os resultados mostrados na Figura 6 permitem inferir, ainda, que a diminuição progressiva das precipitações a partir de julho/agosto e o aumento das temperaturas a partir de agosto/setembro são os fatores limitantes ao cultivo de milho entre julho a fevereiro

Dessa forma as janelas mostradas nos gráficos da Figura 6 deixam claro que o aumento da temperatura nos meses de julho a dezembro faz com que esteja comprometida drasticamente a semeadura da cultura, pois aumenta a ETP e conseqüentemente diminui a precipitação por outro lado o segundo decêndio do mês de abril é possível estimar uma

produção acima dos 50% para todo o estado de Alagoas, além disso, os dados observados durante toda a série denotam um alto risco climático da cultura do milho cultivado nos decêndios do segundo semestre, para todo estado de Alagoas, deixando clara a inviabilidade da semeadura do milho nesse período, portanto os meses de julho a janeiro considerado inaptos para semear o grão, valendo enfatizar que o risco aumenta devido aos baixos índices de precipitação.

**Figura 6.** Produtividade potencial média do milho para as diferentes mesorregiões do Estado de Alagoas.



## 4.3. PROJEÇÕES FUTURAS PARA A SEMEADURA DO MILHO EM ALAGOAS

### 4.3.1 CALIBRAÇÃO DO MODELO DE DOWNSCALING ESTATÍSTICO

Uma das etapas mais importante da calibração de um MDE é analisar se tal modelo é capaz de reproduzir com coerência o clima observado. O MDE foi aplicado aos dados de precipitação, temperaturas máximas e mínimas das cinco estações meteorológicas convencionais do INMET em Alagoas, Água Branca e Pão de Açúcar, Palmeira dos Índios e Porto de Pedras no leste alagoano, cujos resultados individuais serão mostrados a seguir.

Para a precipitação (Figura 7a a 7j), os dados simulados mostram uma excelente relação com os dados observados, nas cinco localidades. Para cada município mostra-se a climatologia observada ao lado da simulada por cada MCG, ao lado da comparação com a média (*ensemble*) dos modelos. O teste comparativo com cada MCG individual indica que todos representaram bem o ciclo climatológico, permitindo distinguir os MCGs que subestimam (superestimam) tal climatologia.

Alguns MCGs destacam-se quanto a estes vieses na precipitação. O CNRM-CM5 e o MPI-ESM-MR superestimam a observação principalmente no primeiro semestre em todas as localidades, com destaque maior para Água Branca (Figura 7a), Pão de Açúcar (Figura 7b) e Palmeira dos Índios (Figura 7c). No trimestre maio-junho-julho, o mais chuvoso em Alagoas, a tendência dos MCGs foi de subestimar as chuvas.

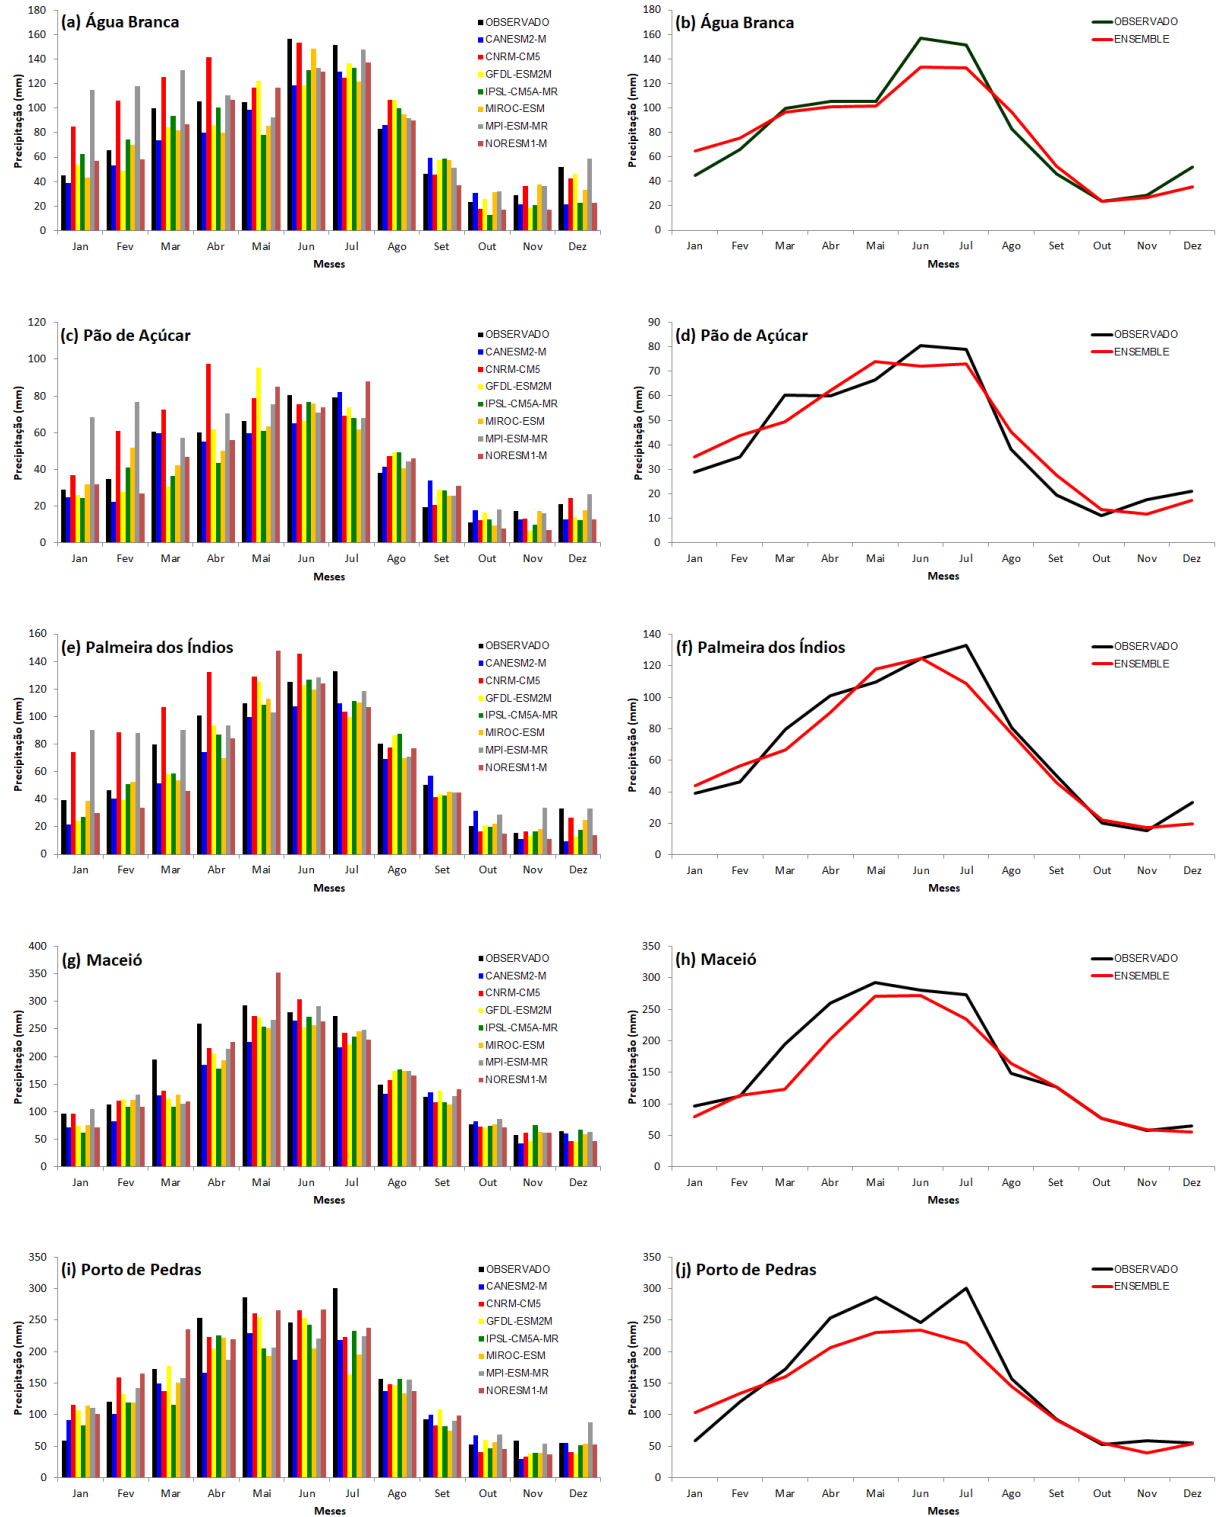
Esta alternância entre MCGs é ponderada pelo valor médio mostrado nos *ensembles* de cada local. Percebe-se nas Figuras 7h e 7j, para Maceió e Porto de Pedras, que os MCGs subestimam as chuvas do trimestre mais chuvoso com maior intensidade.

Para as temperaturas máximas, Figura 8a a 8j, também houve extrema concordância entre a climatologia observada e simulada, com pequena subestimativa dos valores nos meses mais quentes do ano, em todas as localidades, e leve superestimação nos meses mais frios, com exceção das estações do leste alagoano, Maceió (Figura 8g,h) e Porto de Pedras (Figura 8i,j).

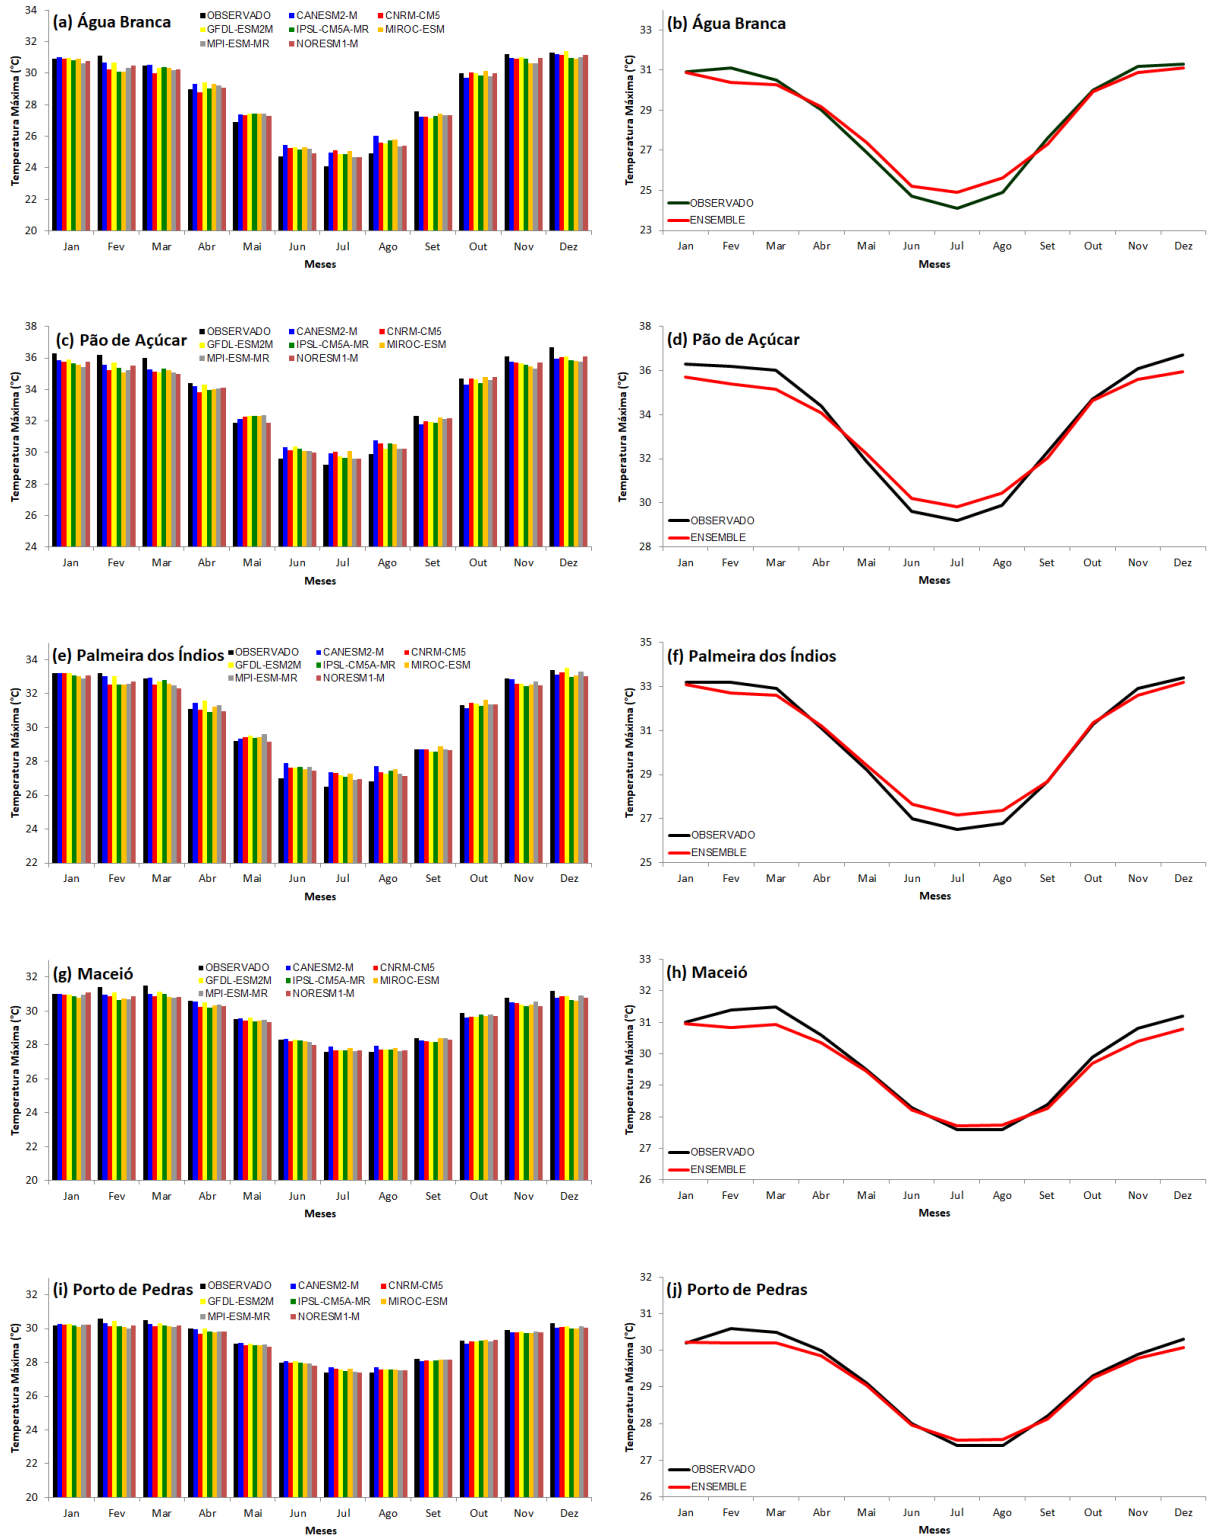
As temperaturas mínimas mostram ainda uma melhor concordância entre a climatologia observada e dos MCGs que as temperaturas máximas, com características similares de sub(super)estimativas (Figura 9a a 9j).

A comparação entre os MCGs individuais mostra boa relação entre observações e simulações, mas exige alguns estudos analíticos mais abrangentes, caso sejam utilizados em estudos independentes. O resultado por *ensemble* permite concluir que, se os dados projetados para o período base (1979-2000) estão muito próximos dos dados observados, as projeções futuras dos MCGs, ou de seu *ensemble*, também poderão ser considerados confiáveis (KAZMI ET AL, 2015; ALI ET AL, 2019; SADDIQUE ET AL, 2019).

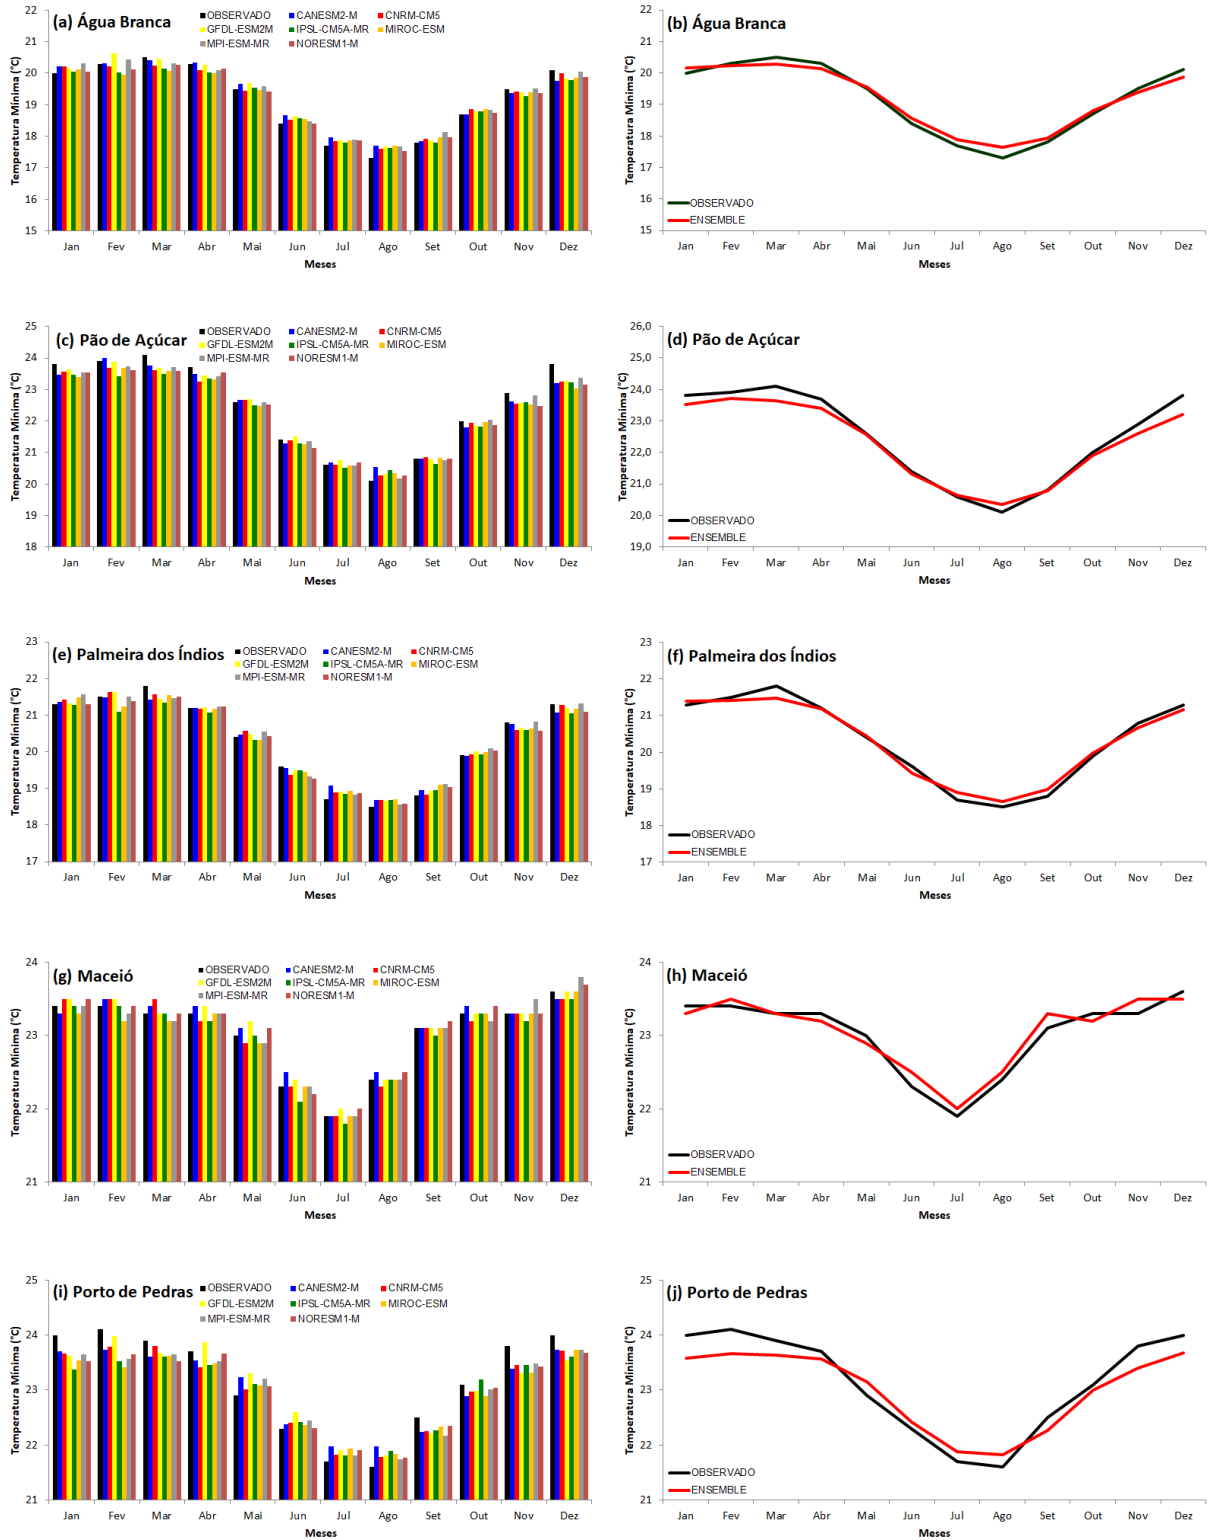
**Figura 7.** Climatologia da precipitação acumulada observada x simulada pelos MCGs e observada x ensemble de todos os MCGs para Água Branca (a, b), Pão de Açúcar (c,d), Palmeira dos Índios (e,f), Maceió (g,h) e Porto de Pedras (i,j).



**Figura 8.** Climatologia da temperatura máxima média observada x simulada pelos MCGs e observada x ensemble de todos os MCGs para Água Branca (a, b), Pão de Açúcar (c,d), Palmeira dos Índios (e,f), Maceió (g,h) e Porto de Pedras (i,j).



**Figura 9.** Climatologia da temperatura mínima média observada x simulada pelos MCGs e observada x ensemble de todos os MCGs para Água Branca (a, b), Pão de Açúcar (c,d), Palmeira dos Índios (e,f), Maceió (g,h) e Porto de Pedras (i,j).



### 4.3.2 VALIDAÇÃO DO MODELO DE DOWNSCALING ESTATÍSTICO

A Tabela 1 mostra a validação decendial da calibração do método de *downscaling* estatístico para a precipitação dos MCGs do CMIP5 para o período 2001-2010, em seguida, as Tabelas 2 e 3 são para as temperaturas máximas e mínimas.

São mostradas as comparações entre observações e simulações dos valores das médias e desvios padrão, da correlação, da raiz do erro quadrático médio, da razão entre variâncias e PDFscore. Todos os valores e relações foram estatisticamente significantes ao nível de 95% pelo teste t-student, os valores mais elevados foram obtidos para as temperaturas máximas seguido pelas temperaturas mínimas e precipitação, o que demonstra a natureza preditiva das temperaturas.

Para a precipitação os valores médios observados e previstos foram próximos, assim como os respectivos desvios-padrão. O RMSE variou de 2,9mm em Palmeira dos Índios a 5,6mm em Porto de Pedras. A razão das variâncias próximas a 1 indica boa concordância entre as variabilidades observadas e simuladas, assim como os valores do PDFscore próximos de 1 indicam eficiência da simulação em representar os extremos da distribuição observada.

Para as temperaturas, os parâmetros indicam simulações mais satisfatórias em relação às observações, destacando-se os valores elevados de correlação, principalmente das temperaturas máximas. Observa-se RMSE acima de 1 apenas para as temperaturas máximas das cidades do sertão e agreste, e inferiores a 1 nas demais, indicando tendência de valores inferiores das simulações em relação as observações. Para os demais parâmetros as avaliações são similares as feitas para a precipitação.

Tabela 1. Medidas de performance estatística para o período de validação da precipitação.

Precipitação	$\bar{X}_{Obs}$	$\bar{X}_{Sim}$	S Obs	S Sim	r	RMSE	RV	PDFesc
Á. Branca	2,89	2,69	3,76	3,42	0,55	3,5	0,82	0,94
P.de Açúcar	1,49	1,39	2,09	1,89	0,53	2,1	0,83	0,94
P.dos Índios	2,38	2,03	3,16	2,49	0,60	2,9	0,62	0,93
Maceió	5,07	4,85	5,66	4,78	0,63	5,2	0,71	0,94
P.de Pedras	4,80	4,60	5,61	4,99	0,56	5,6	0,79	0,95

Tabela 2. Medidas de performance estatística para o período de validação da temperatura máxima.

Temp Máxima	$\bar{X}_{Obs}$	$\bar{X}_{Sim}$	S Obs	S Sim	r	RMSE	RV	PDFesc
Á. Branca	28,4	28,5	2,75	2,52	0,86	1,40	0,85	0,94
P.de Açúcar	33,3	33,4	2,80	2,54	0,84	1,52	0,82	0,92
P.dos Índios	30,4	30,5	2,74	2,52	0,88	1,32	0,84	0,94
Maceió	29,5	29,6	1,54	1,40	0,82	0,89	0,83	0,93
P.de Pedras	29,0	29,1	1,26	1,12	0,84	0,69	0,79	0,92

Tabela 3. Medidas de performance estatística para o período de validação da temperatura mínima.

Temp Mínima	$\bar{X}_{Obs}$	$\bar{X}_{Sim}$	S Obs	S Sim	r	RMSE	RV	PDFesc
Á. Branca	19,1	19,1	1,23	1,04	0,77	0,78	0,72	0,90
P.de Açúcar	22,2	22,3	1,52	1,36	0,79	0,94	0,80	0,93
P.dos Índios	20,2	20,2	1,31	1,17	0,75	0,88	0,79	0,94
Maceió	20,9	20,9	1,16	0,93	0,59	0,97	0,64	0,89
P.de Pedras	22,9	23,0	1,06	0,94	0,62	0,87	0,78	0,93

### 4.3.3 CENÁRIOS CLIMÁTICOS FUTUROS: RCP4.5

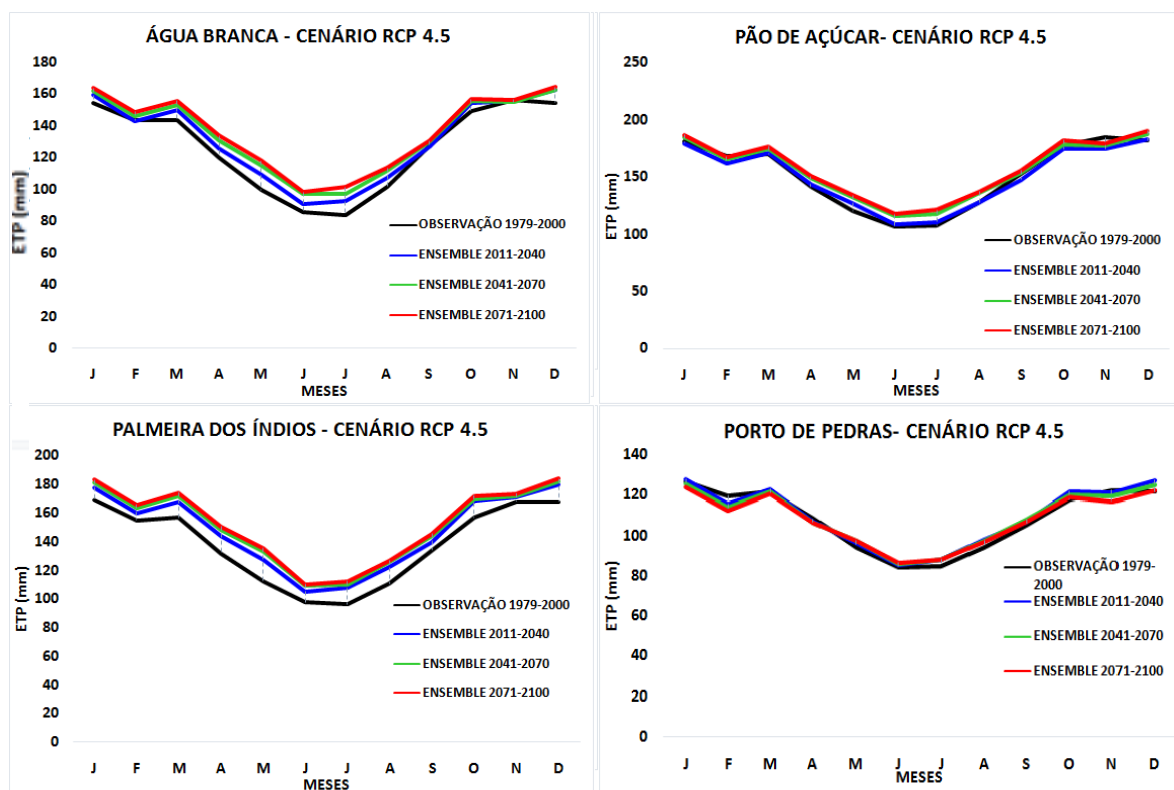
Os resultados da fase de calibração mostraram que trabalhar com o ensemble dos MCGs traz resultados mais confiáveis do que para cada MCG de forma individual. Desta seção em diante todos os resultados dos cenários serão apresentados desta maneira, com exceção das simulações futuras da produtividade.

As projeções da ETP obtidas das temperaturas máximas e mínimas pelo método de Hargreaves e Samani indicam leves alterações em relação à climatologia observada em 1979-2000. A Figura 10 mostra que, para os intervalos de 30 anos entre 2011 e 2100 (2011-2040; 2041-2070 e 2071-2100), a ETP tende a ser mais elevada a cada subperíodo em Água Branca, em menor intensidade em Pão de Açúcar, novamente em maior intensidade em Palmeira dos Índios e quase sem diferença em relação a média de referência para Porto de Pedras, mas com valores levemente inferiores.

A variação da ETP reflete diretamente na produtividade, pois esta variável indica em qual intensidade a água precisa ser repostada para a cultura em situações de déficit hídrico.



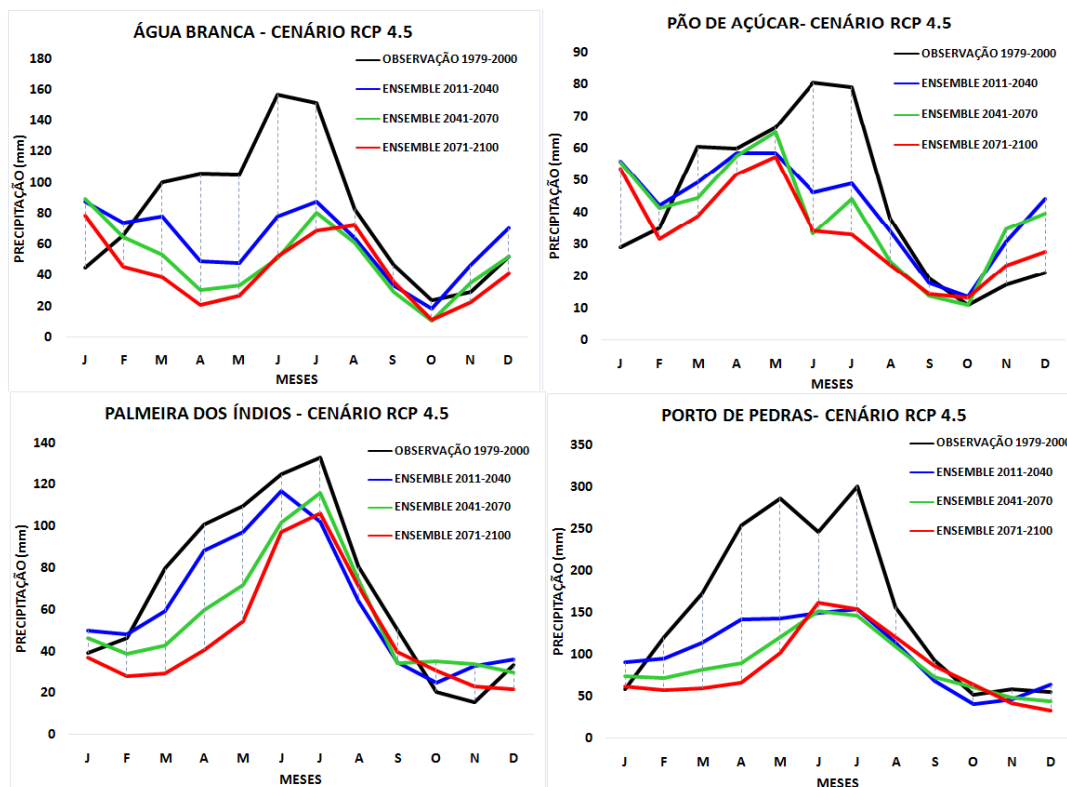
**Figura 10** – Na sequência, climatologia futura da ETP obtida do ensemble dos MCGs para o cenário RCP4.5 em Água Branca, Pão de Açúcar, Palmeira dos Índios e Porto de Pedras.



Para a precipitação os resultados indicam redução significativa em relação ao período de referência. A Figura 11 mostra que as curvas climatológicas para o cenário futuro seguem o padrão da observação, no entanto com a diminuição da quantidade de chuvas principalmente nos primeiros seis a oito meses do ano, com destaque para os meses mais chuvosos trás consigo um cenário preocupante para o futuro da cultura do milho no Estado, dessa forma o sinal de alerta aparece nesse momento. Também nota-se a diminuição progressiva no tempo, com 2011-2040 com acumulados inferiores a climatologia observada, 2041-2070 com acumulados inferiores a 2011-2040 e 2071-2100 inferior a 2071-2100.

Para Água Branca, a redução da precipitação acumulada projetada para 2011-2040 é de 42% em relação a 1979-2000, de 56% em 2041-2070 e próxima dos 60% de 2071 a 2100. Em Pão de Açúcar a redução de chuvas prevista até 2100 é de aproximadamente 40%. Para Palmeira dos Índios projeta-se quedas acentuadas nos índices de chuvas em torno de 10% a cada 30 anos, com destaque para a quadra chuvosa de abril a julho. Em Porto de Pedras o cenário é mais preocupante, com redução de 40% das chuvas nos primeiros 30 anos, de 50% entre 2041 a 2070 e mantendo-se neste patamar de 2071 a 2100.

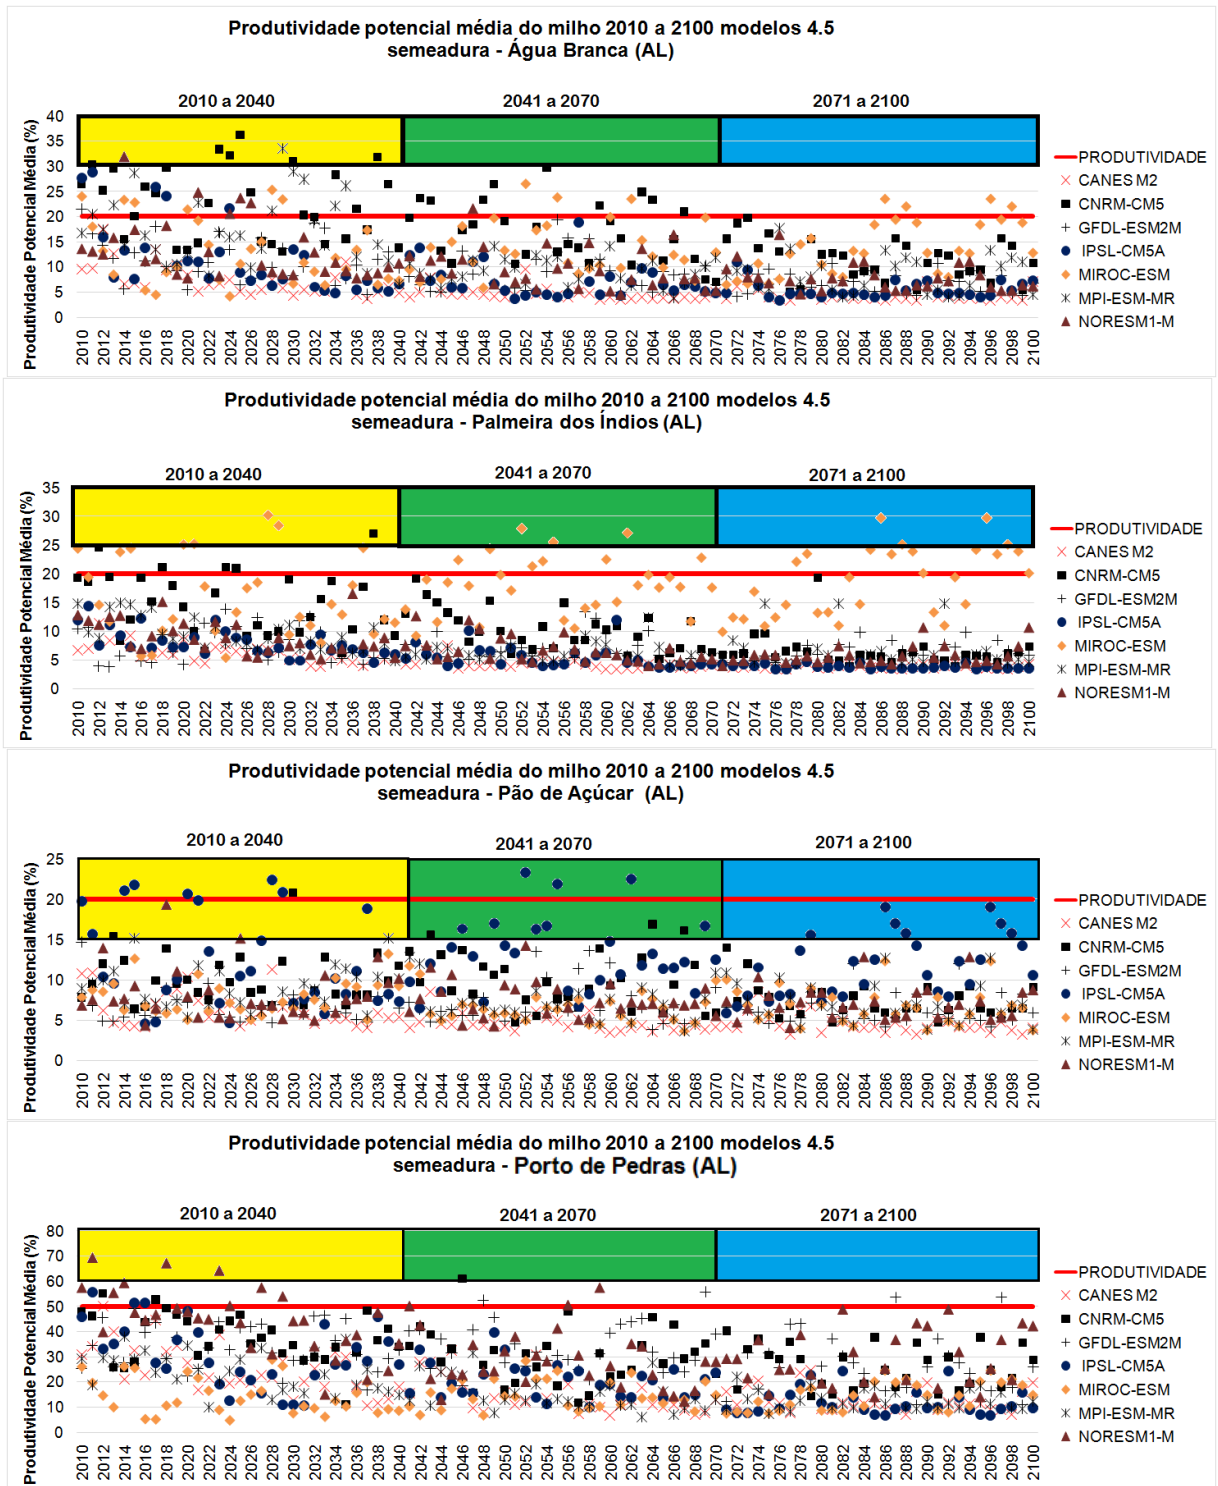
**Figura 11** – Na sequência, climatologia futura da precipitação obtida do ensemble dos MCGs para o cenário RCP4.5 em Água Branca, Pão de Açúcar, Palmeira dos Índios e Porto de Pedras.



Pode-se observar dos resultados a combinação de leves a moderados aumentos da ETP, associados à redução das chuvas. Aplicando tais dados ao modelo agrometeorológico, tem-se como consequência a drástica redução da produtividade relativa.

A Figura 12 mostra a variação da produtividade relativa futura de cada MCG ao longo de cada subperíodo analisado. Para Água Branca o MCG GFDL-ESM-2M se destaca entre os demais nos subperíodos 2011-2040 e 2041-2070 como o que estima a maior produtividade relativa, em torno de 25%, atingindo em alguns anos o pico de 35%. No período 2071-2100 as produtividades estimadas caem ainda mais, com o MPI-ESM-MR projetando as maiores produtividades, mas que não chegam a ultrapassar 25% em alguns anos. Em Pão de Açúcar, o MCG MIROC-ESM é o que projeta as maiores produtividades, mas inferiores a 25%. Em Palmeira dos Índios destaca-se o MCG MPI-ESM-MR, com produtividades que no máximo atingem os 30%, e em Porto de Pedras, o CNRM-CM5 projeta as maiores produtividades relativas, que podem atingir os 60%.

**Figura 12** – Plumas de produtividade potencial de cada MCG de 2011 a 2100 no cenário RCP4.5.



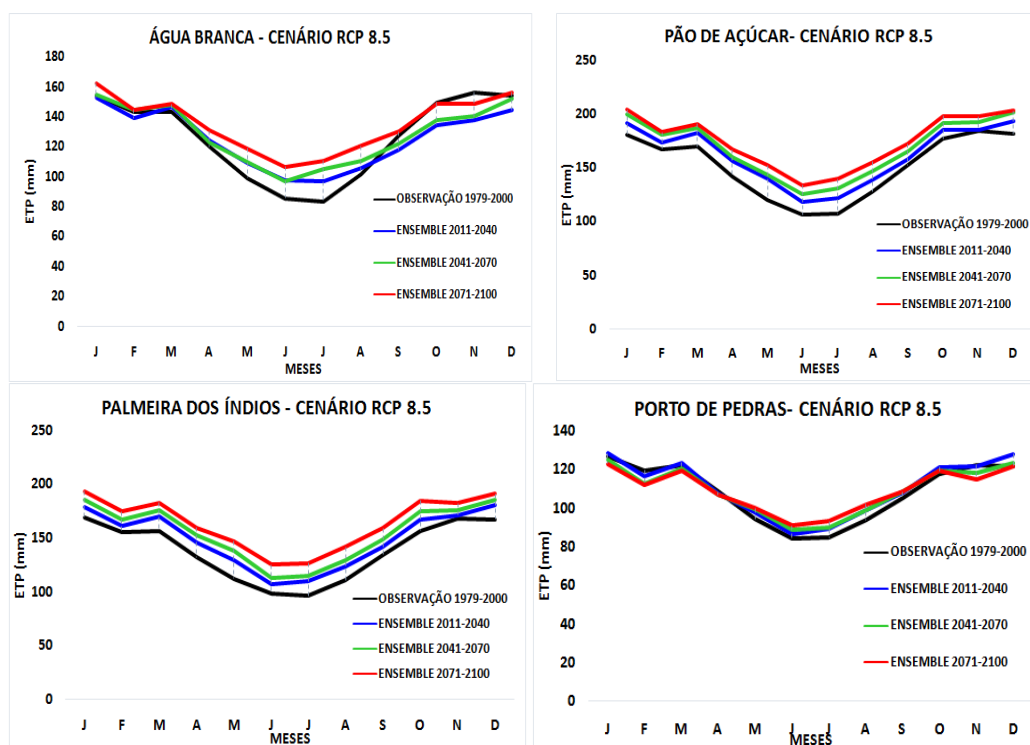
#### 4.3.4 CENÁRIOS CLIMÁTICOS FUTUROS: RCP8.5

O cenário RCP8.5 é comumente conhecido como o cenário climático futuro mais pessimista, por sua natureza de elevada forçante radiativa resultante do consumo incessante de combustíveis fósseis. Normalmente, espera-se impactos mais negativos, a depender da aplicação, neste cenário.

A climatologia calculada da ETP para os subperíodos futuros mostram comportamento similar ao obtido no cenário RCP4.5, no entanto, há uma maior distância entre os valores previstos e o clima observado, que cresce positiva quanto mais se avança até o final do século (Figura 13).

Da Figura 13, para Água Branca o aumento da ETP é acentuado entre maio e agosto, e inferior ao período de referência entre setembro e janeiro, com um saldo final positivo de aumento. Em Pão de Açúcar e Palmeira dos Índios, projeta-se um aumento quase constante dos valores da ETP em relação a referência para todos os meses do ano, que é incrementado de forma quase linear a cada subperíodo analisado até o fim do século. Porto de Pedras apresenta as menores diferenças climatológicas em relação ao clima observado, o que sugere um aumento menor das temperaturas na faixa leste de Alagoas.

Figura 13 - Na sequência, climatologia futura da ETP obtida do ensemble dos MCGs para o cenário RCP8.5 em Água Branca, Pão de Açúcar, Palmeira dos Índios e Porto de Pedras

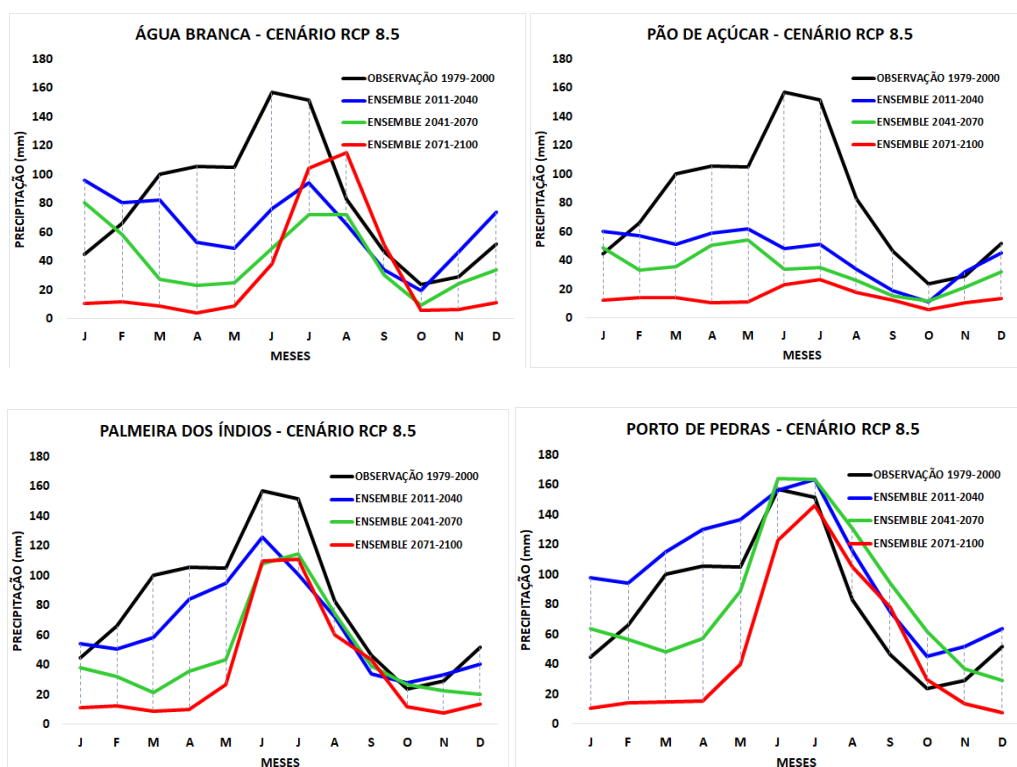


A Figura 14 mostra a distribuição climatológica das chuvas acumuladas no cenário RCP8.5, comparada ao período de referência. Em Água Branca, projeta-se redução significativa das chuvas nos três subperíodos analisados, inclusive com deslocamento do período mais chuvoso projetado no período 2071-2100, que passaria de abril a julho para junho a setembro.

Em Pão de Açúcar ocorreria a redução mais drástica das chuvas, que se intensificaria a cada subperíodo. Palmeira dos índios apresenta redução moderada das chuvas no período 2011-2040, e mais acentuada em 2041-2070 e 2071-2100, respectivamente, apesar do acumulado no período chuvoso ser similar nos três subperíodos.

Porto de Pedras é o caso mais interessante, pois é a única localidade onde projeta-se aumento das chuvas. Isto ocorreria no subperíodo 2011-2040. Em 2041-2070 haveria redução de fevereiro a maio e aumento a partir de junho. Por fim, apenas no final do século, entre 2071-2100, o município experimentaria a redução acentuada no primeiro semestre, com aumento discreto no segundo semestre, mas com valores próximos a climatologia de referência.

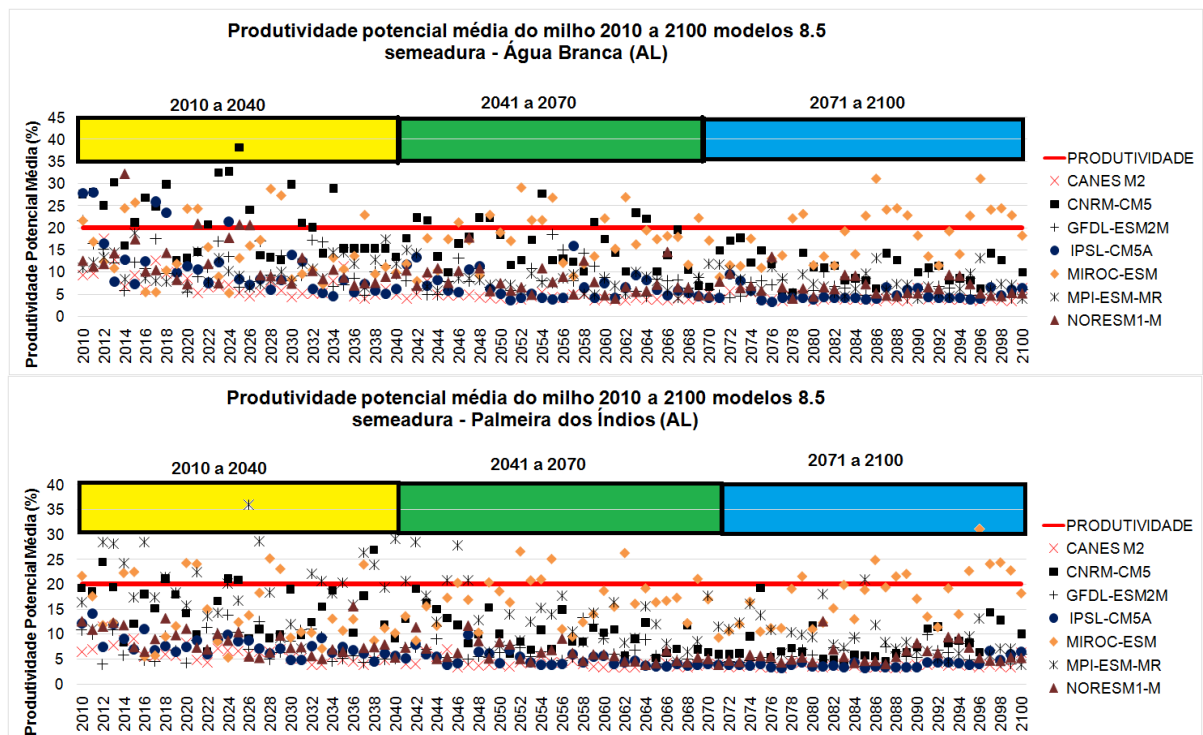
**Figura 14** – Na sequência, climatologia futura da precipitação obtida do ensemble dos MCGs para o cenário RCP8.5 em Água Branca, Pão de Açúcar, Palmeira dos Índios e Porto de Pedras.




Estes resultados, quando comparados aos obtidos no cenário RCP4.5, aponta para produtividades relativas ainda mais reduzidas em Água Branca e Palmeira dos Índios, valores similares em Pão de Açúcar, e maior produtividade em Porto de Pedras, associada provavelmente ao aumento das chuvas projetado para 2011-2040.

A Figura 15 mostra a variação da produtividade relativa futura de cada MCG ao longo de cada subperíodo analisado. Em Água Branca, é notável a redução da produtividade a cada período. Em 2011-2040 e 2041-2070, os MCGs com maiores produtividades projetadas são o GFDL-ESM2M e o MPI-ESM-MR. No final do século o MPI-ESM-MR é o que aponta para maiores produtividades relativas, chegando a 30%, com os demais MCGs abaixo dos 15%. Em palmeira dos Índios e Pão de Açúcar, s MCGs MIROC-ESM e MPI-ESM-MR tem comportamento similar em toda a série, projetando as maiores produtividades, que varia de 10% a pouco mais de 30%. Em Porto de Pedras, a maioria dos MCGs apresenta produtividades relativas em torno de 40%, com destaque para o CNRM-CM5 nos três subperíodos.

**Figura 15** – Plumas de produtividade potencial de cada MCG de 2011 a 2100 no cenário RCP8.5.







## 5 CONCLUSÕES

A partir dos resultados e condições climatológicas do estado, foram Gerados cenários futuros, verificando os impactos na produtividade do milho através de um modelo agrometeorológico, comparando com a produtividade atual observada ao longo do século 21, que por sua vez mostrou um cenário preocupante para Alagoas, tendo em vista que a produtividade média esperada para o futuro das regiões de Sertão e Agreste poderá não ultrapassar 20%.

Além disso, foi realizado um zoneamento identificando as melhores épocas para a semeadura do milho para o Estado de Alagoas baseado no histórico do rendimento médio das safras agrícolas visualizadas pelo mapeamento realizado no decorrer dos anos de (1980 a 2015), que demonstrou que as datas estabelecidas pela Portaria de N° 167 de 2 de outubro de 2013, não se aplicam a todo o estado. As datas tradicionalmente indicadas para o plantio do milho, 20/05 e 20/06, não são plenamente favoráveis para a semeadura do milho nas regiões do sertão e agreste. Para a faixa leste a data de plantio poderia ser antecipada para o segundo decêndio de fevereiro, que pelo zoneamento realizado já apresentaria favorabilidade para a semeadura. Para atingir tais resultados, foi validado um modelo agrometeorológico de penalização por déficit hídrico aplicado a cultura do milho em Alagoas.

Assim, através do conhecimento retrógrado pôde-se realizar validações de 7 MCGs para dois diferentes cenários futuros de mudanças climáticas, RCPs 4.5 e 8.5, utilizando para isto a metodologia de *downscaling* estatístico, para as variáveis precipitação e ETP, para estações meteorológicas representativas de cada mesorregião alagoana. Os resultados apontam para redução da precipitação e aumento da ETP, principalmente para os períodos 2041-2070 e 2071-2100. Esta combinação de fatores, caso confirmadas, poderão levar à uma acentuada queda do rendimento do milho de sequeiro em Alagoas.

Ressalta-se que a presente pesquisa se constitui numa contribuição para gerar possibilidades de monitorar as safras de outras culturas em Alagoas. Portanto, faz-se necessário avaliar o passado através séries históricas de produtividade para poder prever o futuro que resulte em informações em tempo hábil para prevenir prejuízos sociais e econômicos para a população.



## **6 SUGESTÕES PARA TRABALHOS FUTUROS**

- Avaliar a sensibilidade do modelo agrometeorológico para estimar produtividade de outras culturas de sequeiro de ciclo curto, permitindo analisar o padrão de déficit hídrico que leva a perda de produtividade em cada mesorregião do estado de Alagoas, estendendo-se para toda a região Nordeste.
- Estudar mais cenários de mudanças climáticas para antecipar situações de déficit hídrico em Alagoas e toda a região Nordeste.

## 7 REFERÊNCIAS BIBLIOGRÁFICAS

- ALI, S.; EUM, H-I.; JAEPIL, C.; LI, D.; KHAN, F.; DAIRAKU, K.; SHRESTHA, M. L.; HWANG, S.; NASEEM, W.; FAHAD, S. Assessment of climate extremes in future projections downscaled by multiple statistical downscaling methods over Pakistan. **Atmospheric Research**, v. 222, p. 114-133, 2019.
- ALLISON, M.T., CALVIN, K.V., SMITH, S.J., KYLE, G.P., VOLKE, A., PATEL, P., DELGADO-ARIAS, S., BOND-LAMBERTY, B., WISE, M.A., CLARKE, L.E., EDMONDS, J.A., 2011. Rcp4.5: a pathway for stabilization of radiative forcing by 2100. **Climatic Change** 109, 77–94, <http://dx.doi.org/10.1007/s10584-011-0151-4>.
- ALLSOPP, T.; LOPEZ, J. A.; PLUMMER, N. WMO. Guidelines on Climate Observation Networks and Systems. WMO Technical Document, Geneva, Switzerland, 2003.
- ALVALA, R. C. C.; CUNHA, A. P. M. A.; BRITO, S. S. B.; SELUCHI, M. E.; MARENGO, J. A.; MORAES, O. L. L.; CARVALHO, M. A. Drought monitoring in the Brazilian Semiarid region. **Anais da Academia Brasileira de Ciências**, 2017. <http://dx.doi.org/10.1590/0001-3765201720170209>.
- ALVES, G. C. Efeito da inoculação de bactérias Diazotróficas dos gêneros *Herbaspirillum* e *Bulkholderia* em genótipos de milho. **Dissertação (Mestrado em Ciências)**, 65 f. Universidade Federal Rural do Rio de Janeiro. Seropédica, RJ, 2007.
- ARORA, V. K. et al. The effect of terrestrial photosynthesis down-regulation on the 20th century carbon budget simulated with the CCCma Earth System Model, **Journal of Climate**, v. 22, p. 6066-6088, 2009.
- ARORA, V. K.; BOER, G. J. Uncertainties in the 20th century carbon budget associated with land use change, **Global Change Biology**, v. 16(12), p. 3327-3348, 2010.
- ASSAD, E. D.; MARIN, F. R.; EVANGELISTA, S.R.; PILAU, F. G.; FARIAS, J. R. B.; PINTO, H. S.; ZULLO JÚNIOR, J. Sistema de previsão da safra de soja para o Brasil. **Pesquisa Agropecuária Brasileira**, v.42, n.5, p.615-625, 2007.
- BALBINOT JR, A. A.; BACKES, R. L.; ALVES, A. C.; OGLIARI, J. B.; FONSECA, J. A. Contribuição de componentes de rendimento na produtividade de grãos em variedades de polinização aberta de milho. **Revista Brasileira Agrociência**, Pelotas, v. 11, n. 2, p. 161-166, 2015.
- BATISTA, B.D. Promoção de crescimento vegetal por *Bacillus* sp. RZ1MS9: dos genes ao campo. **Tese (Doutorado em Ciências)**, 108f. Universidade de São Paulo, Piracicaba, SP, 2017.
- BENTSEN, M.; BETHKE, I.; DEBERNARD, J. B.; IVERSEN, T.; KIRKEVÅG, A.; SELAND, Ø.; DRANGE, H.; ROELANDT, C.; SEIERSTAD, I. A.; HOOSE, C.; KRISTJÁNSSON, J. E. The Norwegian Earth System Model, NorESM1-M – Part 1: Description and basic evaluation of the physical climate, **Geoscientific Model Development**, v. 6, p. 687–720, 2012.
- BRANDS, S.; HERRERA, S.; SAN-MARTIN, D.; GUTIERREZ, J. M. Validation of the ensemble's global climate models over southwestern Europe using probability density functions, from a downscaling perspective. **Climate Research**, v. 48, n. 2-3, p. 145–161, 2011a.

BRANDS, S.; TABOADA, J. J.; COFINO, A. S.; SAUTER, T.; SCHNEIDER, C. Statistical downscaling of daily temperatures in the Iberian Peninsula from global climate models: validation and future scenarios. **Climate Research**, v.48, n. 2-3, p. 163–176, 2011b.

BRANDS, S.; GUTIERREZ, J. M.; HERRERA, S. On the Use of Reanalysis Data for Downscaling. **Journal of Climate**, v.25, n. 1, p. 2517-2526, 2012.

BRITO, S. S. B.; CUNHA, A. P. M. A.; CUNNINGHAM, C. C.; ALVALÁ, R. C.; MARENGO, J. A.; CARVALHO, M. A. Frequency, duration and severity of drought in the Semiarid Northeast Brazil region. **International Journal of Climatology**, v. 23, p. 200-213, 2017.

CAMILO, J. A.; ANDRADE, C. L. T.; AMARAM, T. A.; TIGGES, C. H. P.; MELO, M. L. A.; CHAN, C. S.; GARCIA, A. G.; Impact of Climate Change on Maize Grown in the Brazilian Cerrado. **ASABE 2018 Annual International Meeting**, 7p.

COFIÑO, A. S.; SAN-MARTÍN, D.; GUTIÉRREZ, J. M. A Web Portal for Regional Projection of Weather Forecast Using GRID Middleware. In: Shi Y., van Albada G.D., Dongarra J., Sloot P.M.A. (eds) Computational Science – ICCS 2007. **ICCS 2007**. Lecture Notes in Computer Science, vol 4489. Springer, Berlin, Heidelberg, 2007.

CONAB. Observatório Agrícola - Acompanhamento da Safra Brasileira-Grãos. V. 5 - SAFRA 2017/18 - N. 7 - Sétimo levantamento | ABRIL 2018.

CONAB. Revista Indicadores da Agropecuária. Disponível em: <<https://www.conab.gov.br/info-agro/precos/revista-indicadores-da-agropecuaria>>. Acessado em: 30 de ago. 2019.

CORRÊA, S. T. R.; DOURADO-NETO, D.; LORENÇONI, R.; SCARPARE, F. V.; VIVIAN, R.; RUIZ, E. T. Aplicações e limitações da modelagem em agricultura - Revisão. **Revista de Agricultura**. Piracicaba, v. 86, p. 1-13, 2011.

CUENCA, M. A. G. Diagnóstico agrossocioeconômico da agropecuária no município de Barra dos Coqueiros. Aracaju: **Embrapa Tabuleiros Costeiros**, 2014. 9p.

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

DOORENBOS, J.; KASSAM, A. H. **Yield response to water**. Roma, Irrigation and Drainage Paper 33, FAO, 179p, 1979.

DOORENBOS, J.; KASSAM, A. H. **Efeito da água no rendimento das culturas**. Tradução de GHEYI, H. R.; SOUSA, A. A.; DAMASCENO, J. F. 2. ed. Campina Grande: UFPB, 2000, 221p. (Estudos FAO: Irrigação e Drenagem, 33).

DUFRESNE, J. L.; FOUJOLS, M. A.; DENVIL, S.; CAUBEL, A.; MARTI, O.; AUMONT, O.; BALKANSKI, Y.; BEKKI, S.; BELLENGER, H.; BENSHILA, R.; BONY, S.; BOPP, L.; BRACONNOT, P.; BROCKMANN, P.; CADULE, P.; CHERUY, F.; CODRON, F.; COZIC,

A.; CUGNET, D.; DE NOBLET, N.; DUVEL, J. P.; ETHE, C.; FAIRHEAD, L.; FICHEFET, T.; FLAVONI, S.; FRIEDLINGSTEIN, P.; GRANDPEIX, J. Y.; GUEZ, L.; GUILYARDI, E.; HAUGLUSTAINE, D.; HOURDIN, F.; IDELKADI, A.; GHATTAS, J.; JOUSSAUME, S.; KAGEYAMA, M.; KRINNER, G.; LABETOULLE, S.; LAHELLEC, A.; LEFEBVRE, M. P.; LEFEVRE, F.; LEVY, C.; LI, Z. X.; LLOYD, J.; LOTT, F.; MADEC, G.; MANCIP, M.; MARCHAND, M.; MASSON, S.; MEURDESOF, Y.; MIGNOT, J.; MUSAT, I.; PAROUTY, S.; POLCHER, J.; RIO, C.; SCHULZ, M.; SWINGEDOUW, D.; SZOPA, S.; TALANDIER, C.; TERRAY, P.; VIOVY, N.; VUICHARD, N. Climate change projections using the IPSL-CM5 Earth System Model: from CMIP3 to CMIP5. **Climate Dynamics**, v. 40, p. 2123–2165, 2013.

DUNNE, J. P.; JOHN, J. G.; ADCROFT, A. J.; GRIFFIES, S. M.; HALLBERG, R. W.; SHEVLIAKOVA, E.; STOUFFER, R. J.; COOKE, W.; DUNNE, K. A.; HARRISON, M. J.; KRASTING, J. P.; MALYSHEV, S. L.; MILLY, P. C. D.; PHILLIPPS, P. J.; SENTMAN, L. T.; SAMUELS, B. L.; SPELMAN, M. J.; WINTON, M.; WITTENBERG, A. T.; ZADEH, N. GFDL's ESM2 Global Coupled Climate–Carbon Earth System Models. Part I: Physical Formulation and Baseline Simulation Characteristics. **Journal of Climate**, v. 25, p. 6646–665, 2012.

DUNNE, J. P.; JOHN, J. G.; SHEVLIAKOVA, E.; STOUFFER, R. J.; KRASTING, J. P.; MALYSHEV, S. L.; MILLY, P. C. D.; SENTMAN, L. T.; ADCROFT, A. J.; COOKE, W.; DUNNE, K. A.; GRIFFIES, S. M.; HALLBERG, R. W.; HARRISON, M. J.; LEVY, H.; WITTENBERG, R. W.; PHILLIPS, P. J.; ZADEH, N. GFDL's ESM2 Global Coupled Climate–Carbon Earth System Models. Part II: Carbon System Formulation and Baseline Simulation Characteristics. **Journal of Climate**, v. 26, p. 2247–2267, 2013.

FAO. FAOSTAT. Food and Agriculture Organization of the United Nations. <http://faostat.fao.org/default.aspx>, 2011.

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

FRICH, P.; ALEXANDER, L. V.; DELLA-MARTA, P.; GLEASON, G.; HAYLOCK, M.; KLEIN TANK, A. M. G.; PETERSON, T. Observed coherent changes in climatic extremes during the second half of the century. **Climate Research**, v. 19, n.3, p.193–212, 2002.

GARCÍA-VILA, R.; FERERES, E. Combining the simulation crop model AquaCrop with an economic model for the optimization of irrigation management at farm level. **European Journal of Agronomy**, P. 21–31, 2012.

GIORGETTA, M. A.; JUNGCLAUS, J.; REICK, C. H.; LEGUTKE, S.; BADER, J.; BOTTINGER, M.; BROVKIN, V.; CRUEGER, T.; ESCH, M.; FIEG, K.; GLUSNAK, K.; GAYLER, V.; HAAK, H.; HOLLWEG, H-D.; ILYINA, T.; KINNE, S.; KORNBLUEH, L.; MATEI, D.; MAURITSEN, T.; MIKOLAJEWICZ, U.; MUELLER, W.; NOTZ, D.; PITHAN, F.; RADDATZ, T.; RAST, S.; REDLER, R.; ROECHNER, E.; SCHMIDT, H.; SCHNUR, R.; SEGSCHEIDER, J.; SIX, K. D.; STOCKHAUSE, M.; TIMMRECK, C.; WEGNER, J.; WIDMANN, H.; WIENERS, K-H.; CLAUSSEN, M.; MAROTZKE, J.; STEVENS, B. Climate and carbon cycle changes from 1850 to 2100 in MPI-ESM simulations for the Coupled Model Intercomparison Project phase 5. **Journal of Advances in Modeling Earth Systems**, VOL. 5, 572–597, doi:10.1002/jame.20038, 2013.

GIORGI, F.; RAFFAELE, F.; COPPOLA, E. The response of precipitation characteristics to global warming from climate projections. **Earth System Dynamics**, v. 10, p. 73–89, 2019.

- GONCALVES, A. R.; PES, M. P.; PEREIRA, E. B.; MARTINS, F. R.; CRUZ SEGUNDO, E. I.; LYRA, A. A. Statistical downscaling of Eta-HadCM3 climate model for near surface wind assessment in Brazil. **Eos Transactions American Geophysical Union**, **91(26)**, Meeting of the Americas Supplement, Abstract GC21A-05, 2010.
- GOODESS, C. M.; ANAGNOSTOPOULOU, C.; BARDOSSY, A.; FREI, C.; HARPHAM, C.; HAYLOCK, M. R.; HUNDECHA, Y.; MAHERAS, P.; RIBALAYGUA, J.; SCHMIDLI, J.; SCHMITH, T.; TOLIKA, K.; TOMOZEIU, R.; WILBY, R. L. An intercomparison of statistical downscaling methods for Europe and European regions—assessing their performance with respect to extreme weather events and the implications for climate change applications. **Climatic Change** (submitted), 2010.
- GREATREX, H. The application of seasonal rainfall forecasts and satellite rainfall estimates to seasonal crop yield forecasting for Africa. (Doctoral thesis). **University of Reading**. 2012.
- GUO, C.; BENTSEN, M.; BETHKE, I.; ILICAK, M.; TJIPUTRA, J.; TONIAZZO, T.; SCHWINGER, J.; OTTERA, O.H. Description and evaluation of NorESM1-F: a fast version of the Norwegian Earth System Model (NorESM). **Geoscientific Model Development**, v. 12, p. 343–362, 2019.
- GUTIÉRREZ, J. M.; SAN-MARTIN, D.; BRANDS, S.; MANZANAS, R.; HERRERA, S. Reassessing statistical downscaling techniques for their robust application under climate change conditions. **Journal of Climate**. v. 26, p. 171-188, 2013.
- GUTZLER, D. S.; ROBBINS, T. O. Climate variability and projected change in the western United States: regional downscaling and drought statistics. **Climate Dynamics**, v. 37, n. 5-6, p. 835–849, 2011.
- HERTIG, E.; MARAUN, D.; BARTHOLY, J.; PONGRACZ, R.; VRAC, M.; MARES, I.; GUTIÉRREZ, J. M.; WIBIG, J.; CASANUEVA, A.; SOARES, P. M. M. Comparison of statistical downscaling methods with respect to extreme events over Europe: Validation results from the perfect predictor experiment of the COST Action VALUE, **International Journal of Climatology**, v. 39, n. 9, p. 3846-3867, 2019.
- HOLDEN, N. M.; BRERETON, A. J. Potential Impacts of Climate Change on Maize Production and the Introduction of Soybean in Ireland. **Irish Journal of Agricultural and Food Research**, Vol. 42 (1), p. 1-15, 2003.
- HOOGENBOOM, G., JONES, P.W. WILKENS, C.H.; PORTER, K.J.; BOOTE, L.A.; HUNT, U.; SINGH, J.L.; LIZASO, J.W.; WHITE, O.; URYASEV, F.S.; ROYCE, R.; OGOSHI, A.J. GIJSMAN, G.Y.; TSUJI, KOO, J. **Decision Support System for Agrotechnology Transfer (DSSAT) Version 4.5**. University of Hawaii, Honolulu, Hawaii. 2012.
- HSIAO, T. S.; HENG, L.; STEDUTO, P.; ROJAS-LARA, B.; RAES, D.; FERERES, E. The FAO Crop Model to Simulate Yield Response to Water: III. Parameterization and Testing for Maize. **Agronomy Journal** , 448-459. 2009.
- HULME, M.; MITCHELL, J.; INGRAM, W.; LOWE, J.; JOHNS, T.; NEW, M.; VINER, D. Climate change scenarios for global impacts studies. **Global Environmental Change**, v. 9, n. 1, p. 3-19, 1999.
- HUNZIKER, S.; BRÖNNIMANN, S.; CALLE, .; MORENO, I.; ANDRADE, M.; TICONA, L.; HUERTA, A.; LAVADO-CASIMIRO, W. Effects of undetected data quality issues on climatological analyses. **Climate of the Past**, v. 14, n. 1, p. 1-20, 2018.

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

IVERSEN, T.; BENTSEN, M.; BETHKE, I.; DEBERNARD, J. B.; KIRKEVÅG, A.; SELAND, Ø.; DRANGE, H.; KRISTJANSSON, J. E.; MEDHAUG, I.; SAND, M.; SEIERSTAD, I. A. The Norwegian Earth System Model, NorESM1-M – Part 2: Climate response and scenario projections, **Geoscientific Model Development**, v. 6, p. 389–415, 2013.

JAME, Y. W.; CUTFORTH, H. W. Crop Growth models for decision support systems. **Canadian Journal of Plant Science**, v. 76, p. 9 - 19, 1996.

JONES, J. W.; HOOGENBOOM, G.; PORTER, C. H.; BOOTE, K. J.; BATCHELOR, W. D.; HUNT, L. A.; WILKENS, P. W.; SINGH, U.; GIJSMAN, A. J.; RITCHIE, J. T. DSSAT cropping system model. **European Journal of Agronomy**, Amsterdam, v. 18, p. 235-265, 2003.

JONES, R. G.; NOGUER, M.; HASSEL, D. C.; HUDSUN, D.; WILSON, S.; JENKINS, G.; MITCHELL, J. F. B. Generating High Resolution climate change scenarios using PRECIS. **Met Office Hadley Centre. Exeter**, p 40, n.1, Apr 2004.

JUNGCLAUS, J. H.; FISCHER, N.; HAAK, H.; LOHMANN, K.; MAROTZKE, J.; MATEI, D.; MIKOLAJEWICZ, U.; NOTZ, D.; VON STORCH, J. S. Characteristics of the ocean simulations in the Max Planck Institute Ocean Model (MPIOM) the ocean component of the MPI- Earth system model. **Journal of Advances in Modeling Earth Systems**, v. 5, p. 422–446, doi:10.1002/jame.20023, 2013.

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

KÜRBIS, K.; MUDELSEE, M.; TETZLAFF.; BRÁZDIL, R. Trends in extremes of temperature, dew point, and precipitation from long instrumental series from central Europe. **Theoretical Applied of Climatology**, v. 98, n. 1-2, 187-195, 2009.

LIU, B.; LIU, F.; WANG, C.; MEI, S. Unit commitment considering flexibility and uncertainty of wind power generation. **Power System Technology**, 39, 730 – 736, 2015.

LORENÇONI, R.; DOURADO-NETO, D.; HEINEMANN, A. B. Calibração e avaliação do modelo ORYZA-APSIM para o arroz de terras altas no Brasil. **Revista Ciência Agronômica**, v. 41, n. 4, p. 605-613, out-dez, 2010.

MACH, K. J.; FREEMAN, P. T.; MASTRANDREA, M. D.; FIELD, C. B. A multistage crucible of revision and approval shapes IPCC policymaker summaries. **Science Policy**, v. 2, n. 8, e1500421, 2016.

MAIA, A. H. N.; MEINKE, H. Probabilistic methods for seasonal forecasting in a changing climate: Cox-type regression models. **International Journal of Climatology**, v. 30(15), p. 2277-2288, 2010. DOI: 10.1002/joc.2042.

MAIA, A. H. N.; PAZIANOTTO, R. A. A.; COELHO, C. A. S. Avaliação da influência do ENOS sobre início da estação chuvosa via modelos semiparamétricos de sobrevivência. Anais da 56ª Reunião Anual da Região Brasileira da Sociedade Internacional de Biometria - RBRAS

e 14º Simpósio de Estatística Aplicada à Experimentação Agronômica - SEAGRO, Universidade Estadual de Maringá, Maringá/SC, 2011.

MARAUN, D.; WETTERHALL, F.; IRESON, A. M.; CHANDLER, R. E.; KENDON, E. J.; WIDMANN, M.; BRIENEN, S.; RUST, H. W.; SAUTER, T.; THEMEL, M.; VENEMA, V. K. C.; CHUN, K. P.; GOODESS, C. M.; JONES, R. G.; ONOF, C.; VRAC, M.; THIELE-EICH, I. Precipitation downscaling under climate change: recent developments to bridge the gap between dynamical models and the end user. **Reviews of Geophysics**, v.48, p. 1-38, 2010.

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

MARENGO J. A.; NOBRE, C.; SALAZAR, L. Regional Climate Change scenarios in South America in the late XXI century: projections and expected impacts. **Nova Acta Leopoldina: Abhandlungen der Deutschen Akademie der Naturforscher Leopoldina**, v. 112, p. 251-265, 2010.

MARENGO, J. A.; ALVES, L. M.; ALVALA, R. C. S.; CUNHA, A. P.; BRITO, S.; MORAES, O. L. L. Climatic characteristics of the 2010-2016 drought in the semiarid Northeast Brazil region. **Anais da Academia Brasileira de Ciências**, v. 23, p. 1-21, 2017.

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. **Dissertação (Mestrado em Meteorologia)** – Instituto Nacional de Pesquisas Espaciais, São José dos Campos-SP, p.64, 2012.

MENDES, D.; MARENGO, J. A. Temporal downscaling: a comparison between artificial neural network and autocorrelation techniques over the Amazon Basin in present and future climate change scenarios. **Theoretical and Applied Climatology**, v. 100, n. 3-4, p. 121-134, 2009.

MENDES, D.; MARENGO, J.; MESQUITA, M. Meteorological Downscaling Methods with Artificial Neural Network Models. **Atmospheric Sciences Newsletter**, v. 3, p. 3-4, 2009.

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

MONTEIRO, J. E. B. A.; ASSAD, E. D.; SENTELHAS, P. C.; AZEVEDO, L. C. Modeling of corn yield in Brazil as a function of meteorological conditions and technological level. **Pesquisa Agropecuária Brasileira**, v. 52, p. 137-148, 2017.

MULLER, W. A.; JUNGCLAUS, J. H.; MAURITSEN, T.; BAEHR, J.; BITTNER, M.; BUDICH, R.; BUNZEL, F.; ESCH, M.; GHOSH, R.; HAAK, H.; ILYINA, T.; KLEINE, T.; KORNBLUEH, L.; LI, H.; MODALI, K.; DOTZ, D.; POHLMANN, H.; ROECKNER, E.; STEMMLER, I.; TIAN, F.; MAROTZKE, J. A Higher-resolution Version of the Max Planck Institute Earth System Model (MPI-ESM1.2-HR). **Journal of Advances in Modeling Earth Systems**, 10.1029/2017MS001217, p. 1383-1413, 2018.

MURRAY-TORTAROLOA, G. N.; JARAMILLOA, V. J.; LARSENA, J. Food security and climate change: the case of rainfed maize production in Mexico. **Agricultural and Forest Meteorology**, 253-254, p. 124-131, 2018.

MURTHY, V. R. K. Crop growth modeling and its applications in agricultural meteorology. In: SIVAKUMAR, M. V. K.; ROY, P. S.; HARMSEN, K. AND SAHA, S. K (Eds.). *Satellite remote sensing and GIS applications in agricultural meteorology*. 2004.

NAKICENOVIC, N.; SWART, R. **Emissions scenarios – special report of the Intergovernmental Panel on Climate Change**. United Kingdom: U.S. Department of Energy Office of Scientific and Technical Information, 2000. 612 p.

NOZAWA, T.; NAGASHIMA, T.; OGURA, T.; YOKOHATA, T.; OKADA, N.; SHIOGAMA, H. Climate change simulations with a coupled ocean-atmosphere GCM called the Model for Interdisciplinary Research on Climate: MIROC, CGER Supercomput. Monogr. Rep., 12, Cent. For Global Environ. Res., Natl. Inst. for Environ. Stud., Tsukuba, Japan, 2007.

PAIXÃO, J. S.; ANDRADE, C. L. T.; GARCIA Y GARCIA, A.; AMARAL, T. A.; STEIDLE NETO, A. J.; MARIN, F. R. An Alternative Approach to the Actual Brazilian Maize Crop Zoning. **Revista Brasileira de Milho e Sorgo**, v.13, n.3, p. 347-363, 2014.

PELLEGRINI, A. F.; ANDEREGG, W. R.; PAINE, C.; HOFFMANN, W. A.; KARTZINEL, T.; RABIN, S. S.; SHEIL, D.; FRANCO, A. C.; PACALA, S. W. Convergence of bark investment according to fire and climate structures ecosystem vulnerability to future change. **Ecology Letters**, v. 20, p. 307-316, 2017.

RAMOS, A. M. Desagregação espacial da precipitação simulada por modelos atmosféricos no Nordeste do Brasil. Universidade Federal da Paraíba, 2000. 96p. (Tese de Mestrado).

RAMIREZ-CABRAL, N. Y. Z.; KUMAR, L.; SHABANI, F. Global alterations in areas of suitability for maize production from climate change and using a mechanistic species distribution model (CLIMEX). **Scientific Reports**, 2017. DOI:10.1038/s41598-017-05804-0.

RANASINGHE, R. Assessing climate change impacts on open sandy coasts: a review, **Earth-Science Reviews**, v. 160, n. 1, p. 20-332, 2016.

RIAHI, K.; RAO, S.; KREY, V.; CHO, C.; CHIRKOV, V.; FISCHER, G.; KINDERMANN, G.; NAKICENOVIC, N.; RAFAJ, P. RCP 8.5 – a scenario of comparatively high greenhouse gas emissions. **Climatic Change**, v. 109, p. 33-57, 2011. <http://dx.doi.org/10.1007/s10584-011-0149-y>.

ROBERTSON, A. W.; KIRSHNER, S.; SMYTH, P. Downscaling of daily rainfall occurrence over Northeast Brazil using a Hidden Markov Model. **Journal of Climate**, v. 17, p. 4407-4424, 2004.

ROCHA JÚNIOR, R. L.; SILVA, F. D. S.; COSTA, R. L.; GOMES, H. B.; HERDIES, D. L.; SILVA, V. P. R., XAVIER, A. C. Analysis of the Space–Temporal Trends of Wet Conditions in the Different Rainy Seasons of Brazilian Northeast by Quantile Regression and Bootstrap Test. **Geosciences**, 9, 457, 2019.

ROSSATO, L.; ALVALÁ, R. C. S.; MARENGO, J. A.; ZERI, M.; CUNHA, A. P. M. A.; PIRES, L. B. M.; BARBOSA, H. A. Impact of Soil Moisture on Crop Yields over Brazilian Semiarid. **Frontiers in Environmental Science**, v. 5, p. 23-29, 2017.

SALAS-MÉLIA, D. A global coupled sea ice-ocean model. **Ocean Modelling**, v. 4, p. 137-172, 2002.

SALAS-MÉLIA, D.; CHAUVIN, F.; DÉQUÉ, M.; DOUVILLE, H.; GUEREMY, J. F.; PLANTON, S.; ROYER, J. F.; TYTECA, S. Description and validation of the CNRM-CM3 global coupled model, CNRM Tech. Rep. 103, 2005.



- SADDIQUE, N.; BEMHOFER, C.; KRONENBERG, R.; USMAN, M. Downscaling of CMIP5 Models Output by Using Statistical Models in a Data Scarce Mountain Environment (Mangla Dam Watershed), Northern Pakistan. **Asia-Pacific Journal of Atmospheric Sciences**, 2019. <https://doi.org/10.1007/s13143-019-00111-2>
- SCARPARE, F. V. Simulação do crescimento da cana-de-açúcar pelo modelo agro-hidrológico SWAP/WOFOST. **Tese (Doutorado em Física do Ambiente Agrícola)**. Escola Superior de Agricultura "Luiz de Queiróz". 163p. 2011.
- SALASSIER, B.; SOARES, A. A.; MANTOVANI, E. C. **Manual de Irrigação**. Editora UFV, 625p, 8.ed, 2008.
- SALVIANO, M. F.; GROppo, J. D.; PELLEGRINO, G. Q. Análise de Tendências em Dados de Precipitação e Temperatura no Brasil. **Revista Brasileira de Meteorologia**, v. 31, n. 1, p. 64-73, 2016.
- SAMPAIO, G.; DIAS, P. L. S. Evolução dos modelos climáticos e de previsão de tempo e clima. **REVISTA USP**, São Paulo, n. 103, p. 41-54, 2014.
- SANTOS, C. A. C.; RAO, T. V. R.; OLINDA, R. A. Trends in Temperature and Growing Season Length in Idaho-USA during the Past Few Decades. **Revista Brasileira de Meteorologia**, v. 30, n. 4, p. 359-370, 2015.
- SILVA, V. P. R.; CAMPOS, J. H. B.; SILVA, M. T. Climate Risk in Maize Crop in the Northeastern of Brazil Based on Climate Change Scenario. **Engenharia Agrícola**, v.32 (6), p. 1176-1183, 2012.
- SILVA, V. P. R.; CAMPOS, J. H. B. C.; SILVA, M. T.; AZEVEDO, P. V. Impacto do aquecimento global sobre o cultivo de feijão caupi no Nordeste do Brasil. **Gestão Agrícola da Água**, v.97, n.1, p.1760-1768, 2014.
- SILVA, F. D. S. Cenários climáticos atuais e futuros da produtividade do algodão herbáceo no Nordeste do Brasil. **Tese (Doutorado em Meteorologia)**, 105f. Universidade Federal de Campina Grande, Campina Grande, PB, 2014.
- SKANSI, M.; BRUNET, M.; SIGRÓ, J.; AGUILAR, E.; GROENING, J. A. A.; BENTANCUR, O. J.; GEIER, Y. R. C.; AMAYA, R. L. C.; JÁCOME, H.; RAMOS, A. M.; ROJAS, C. O.; PASTEN, M. A.; MITRO, S. S.; JIMÉNEZ, C. V.; MARTÍNEZ, R.; ALEXANDER, L. V.; JONES, P. D. Warming and wetting signals emerging from analysis of changes in climate extreme indices over South America. **Global and Planetary Change**, v. 100, p. 295-307, 2013.
- TAYLOR, K. E.; STOUFFER, R. J.; MEEHL, G. A. An Overview of CMIP5 and the Experiment Design. **Bulletin of the American Meteorological Society**, DOI:10.1175/BAMS-D-11-00094.1, 2012.
- TORMA, C. Z. Detailed validation of EURO-CORDEX and Med-CORDEX regional climate model ensembles over the Carpathian Region, **Quarterly Journal of the Hungarian Meteorological Service**, v. 123, n. 2, p. 217-240, 2019.
- THORNTWAITE, G. W. An approach toward a rational classification of climate. **Geographical Review**, New York, v.38, n.1, p.55-94. 1948.

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

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

VANNITSEM, S.; CHOMÉ, F. One-way nested regional climate simulations and domain size. **Journal of climate**, v. 18, n. 1, p. 229-233, 2005.

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

VOLDOIRE, A. E.; SANCHEZ-GOMEZ, D.; SALAS Y MÉLIA, B.; DECHARME, C.; CASSOU, S.; SÉNÉSI, S.; VALCKE, I.; BEAU, A.; ALIAS, M.; CHEVALLIER, M.; DÉQUÉ, J.; DESHAYES, H.; DOUVILLE, E.; FERNANDEZ, G.; MADEC, E.; MAISONNAVE, M. P.; MOINE, S.; PLANTON, D.; SAINT-MARTIN, S.; SZOPA, S.; TYTECA, R.; ALKAMA, S.; BELAMARI, A.; BRAUN, L.; COQUART, F.; CHAUVIN, F. The CNRM-CM5.1 global climate model: description and basic evaluation, **Climate Dynamics**, v. 40(9), p. 2091-2121, 2011.

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

WATANABE, S.; HAJIMA, T.; SUDO, K.; NAGASHIMA, T.; TAKEMURA, T.; OKAJIMA, H.; NOZAWA, T.; KAWASE, H.; ABE, M.; YOKOHATA, T.; ISE, T.; SATO, H.; KATO, E.; TAKATA, K.; EMORI, S.; KAWAMIYA, M. MIROC-ESM 2010: model description and basic results of CMIP5-20c3m experiments. **Geoscientific Model Development**, v. 4, p. 845–872, <https://doi.org/10.5194/gmd-4-845-2011>, 2011.

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

WILBY, R. L.; DAWSON, C. W. The Statistical DownScaling Model (SDSM): Insights from one decade of application. **International Journal of Climatology**, v. 33, p. 1707-1719, 2013.

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.

ZAHARIEV, K.; CHRISTIAN, J. R.; DENMAN, K. L. Preindustrial, historical, and fertilization simulations using a global ocean carbon model with new parameterizations of iron limitation, calcification, and N<sub>2</sub> fixation. **Progress in Oceanography**, v. 77, p. 56-82, 2008.

ZORITA, E.; VON STORCH, H. The analog method as a simple statistical downscaling technique: Comparison with more complicated methods. **Journal of Climate**, v. 12, n. 8, p. 2474-2489, 1999.