



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

IVENS COELHO PEIXOTO

**POTENCIAL PREDITIVO DA PRODUTIVIDADE DO MILHO NAS
MESOREGIÕES DO NORDESTE BRASILEIRO**

MACEIÓ - AL

Agosto de 2021

IVENS COELHO PEIXOTO

**POTENCIAL PREDITIVO DA PRODUTIVIDADE DO MILHO NAS
MESOREGIÕES DO NORDESTE BRASILEIRO**

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 grau de Mestre em Meteorologia, área de concentração Processos de Superfície Terrestre.

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

MACEIÓ - AL

Agosto de 2021

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

Bibliotecário: Marcelino de Carvalho Freitas Neto – CRB-4 – 1767

P379p

Peixoto, Ivens Coelho.

Potencial preditivo da potencialidade do milho nas mesoregiões do Nordeste brasileiro / Ivens Coelho Peixoto. – 2021.

47 f. : il.

Orientador: Fabricio Daniel dos Santos Silva.

Dissertação (Mestrado em Meteorologia) – Universidade Federal de Alagoas. Instituto de Ciências Atmosféricas. Maceió, 2021.

Bibliografia: f. 40-47.

1. Produtividade agrícola. 2. Correlação canônica (Estatística). 3. Brasil, Nordeste. I. Título.

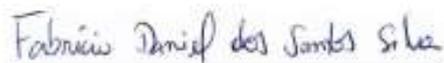
CDU: 551.583:332.66

ATA DE APRESENTAÇÃO PÚBLICA DE DISSERTAÇÃO DE MESTRADO

Aos dezanove dias do mês de agosto do ano de dois mil e vinte e um, às nove horas e trinta minutos, por Videoconferência, Campus A. C. Simões da Universidade Federal de Alagoas (UFAL), perante a Banca Examinadora composta pelo Prof. Dr. Fabricio Daniel dos Santos Silva– Orientador, Profa. Dra. Djane Fonseca da Silva - Membro Interno, Prof. Dr. Lincoln Eloi de Araújo - Membro Externo, o senhor **Ivens Coelho Peixoto** sob a orientação do Prof. Dr. Fabricio Daniel dos Santos Silva–, apresentou publicamente, uma dissertação intitulada: **"POTENCIAL PREDITIVO DA PRODUTIVIDADE DO MILHO NAS MESOREGIÕES DO NORDESTE BRASILEIRO"** número de série, **MET-UFAL-MS-182** como requisito para a obtenção do Grau de Mestre em Meteorologia, área de concentração: Processos de Superfície Terrestre. Após a apresentação, e, seguindo o regimento do Programa de Pós-Graduação em Meteorologia da UFAL no seu Artigo 19, a Banca Examinadora considerou o senhor **Ivens Coelho Peixoto** *aprovado*. Ainda de acordo com o parágrafo único do Artigo 19, o Diploma de Mestre em Meteorologia - área de concentração Processos de Superfície Terrestre será expedido a requerimento do concluinte, anexado a no mínimo 07 (sete) cópias da versão definitiva da dissertação, satisfeitas as modificações indicadas pelos relatores e Banca Examinadora. Eu, Fabricio Daniel dos Santos Silva, Coordenador do Curso de Mestrado em Meteorologia da UFAL, lavrei a presente ata, que vai assinada por mim e pelos componentes da Banca Examinadora.

Maceió-AL, 19 de agosto de 2021.

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



Profa. Dra. Djane Fonseca da Silva
(Membro Interno)



Prof. Dr. Lincoln Eloi de Araújo
(Membro Externo)





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

CERTIFICADO DE APRESENTAÇÃO

N.º de ordem: MET-UFAL-MS-182.

*"POTENCIAL PREDITIVO DA PRODUTIVIDADE DO MILHO NAS MESORREGIÕES
DO NORDESTE BRASILEIRO"*

IVENS COELHO PEIXOTO

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:

Fabrcio Daniel dos Santos Silva

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

Djane Fonseca da Silva

Profª. Dra. Djane Fonseca da Silva
(Membro Interno)

Lincoln Elói de Araújo

Prof. Dr. Lincoln Elói de Araújo
(Membro Externo)

Agosto/2021

AGRADECIMENTOS

Agradeço...

Primeiramente a Deus!

Aos meus pais e minha esposa pelo apoio e incentivo.

Aos amigos que me acompanharam e acompanham nessa caminhada em busca do conhecimento.

Ao orientador Prof. Dr. Fabrício Daniel dos Santos Silva

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão de bolsa Mestrado,

RESUMO

A irregularidade das chuvas e eventos climáticos como secas possuem impacto direto na produção agrícola do Nordeste Brasileiro (NEB). Para melhor compreensão da relação precipitação x produção, as chuvas foram acumuladas em três diferentes semestres, ou estações de cultivo, relativos aos períodos mais chuvosos nas diferentes mesorregiões do NEB: Janeiro a Junho (mesorregiões do norte do NEB), Abril a Setembro (mesorregiões do leste do NEB) e Outubro a Março (mesorregiões do oeste do NEB). Essa pesquisa foi conduzida para o período de 30 anos 1981-2010, e a cultura analisada foi o milho. A correlação direta entre acumulados semestrais e produção mostrou valores fracos a moderados (de 0,3 a 0,7). Um modelo baseado na técnica de análise de correlações canônicas foi construído usando como preditor os acumulados semestrais médios de cada mesorregião e preditando as produções anuais de cada mesorregião. O modelo apresentou destreza elevada quando comparou-se as produções simuladas as observadas, e as correlações passaram a moderadas a fortes (0,4 a 0,9). Ainda, a relação entre dois modos de variabilidade, fases do ENOS e fases do dipolo do Atlântico com a produção foi realizada para o mesmo período, demonstrando que as maiores produções são observadas em anos que combinaram dipolo negativo com as fases ENOS, e com menores produções em anos que combinaram dipolo positivo com fases ENOS, notadamente a combinação dipolo positivo e ENOS positivo. Em anos com a condição combinada de neutralidade dos dois modos, a produção de milho entre 1981 e 2010 foi, também, muito abaixo da média na maior parte das mesorregiões nordestinas.

Palavras-chave: Produtividade agrícola. Análise de Correlação Canônica. Nordeste Brasileiro

ABSTRACT

The irregularity of rainfall and weather events such as drought have a direct impact on agricultural production in the Brazilian Northeast (NEB). For a better understanding of the precipitation x production relationship, rainfall was accumulated in three different semesters, or growing seasons, relative to the rainiest periods in the different NEB mesoregions: January to June (northern NEB mesoregions), April to September (Mesoregions of NEB eastern NEB) and October to March (western NEB mesoregions). This research was conducted for the 30-year period 1981-2010, and the crop analyzed was corn. The direct correlation between half-yearly accumulated figures and production showed weak to moderate values (from 0.3 to 0.7). A model based on the canonical correlations analysis technique was built using as a predictor the average semiannual accumulated in each mesoregion and predicting the annual productions of each mesoregion. The model showed high dexterity when comparing the simulated and observed productions, and the correlations changed from moderate to strong (0.4 to 0.9). Furthermore, the relationship between two modes of variability, ENSO phases and Atlantic dipole phases with production was carried out for the same period, demonstrating that the highest productions are observed in years that combined negative dipole with ENSO phases, and with smaller yields in years that combined positive dipole with ENSO phases, notably the combination positive dipole and positive ENSO. In years with the combined neutrality condition of the two modes, maize production between 1981 and 2010 was also well below average in most of the northeastern mesoregions.

Keywords: Agricultural productivity. Canonical Correlation Analysis. Brazilian Northeast

LISTA DE ILUSTRAÇÕES

- Figura 1.** Mapa da região Nordeste do Brasil identificando os nove Estados, (a) Maranhão, (b) Piauí, (c) Ceará, (d) Rio Grande do Norte, (e) Paraíba, (f) Pernambuco, (g) Alagoas, (h) Sergipe e (i) Bahia, e identificando as 42 mesorregiões, numeradas entre os Estados.....17
- Figura 2.** Distribuição geográfica das 97 estações meteorológicas convencionais no NEB.....19
- Figura 3.** Semestre chuvoso de cada mesorregião do NEB.....19
- Figura 4.** Esquema ilustrativo das etapas utilizadas para as simulações da produção de milho nas mesorregiões do NEB a partir da precipitação acumulada semestral, utilizando ACC.....23
- Figura 5.** Cargas espaciais de X e Y (modo 1) mostram o padrão mais dominante na correlação de precipitação associada com produção acima do normal. A correlação canônica para este par de variáveis foi superior a 0,92. A partir das pontuações temporais (modo 1), os padrões de precipitação, acima ou abaixo da normal, tendem a coincidir com produção acima do normal e vice-versa. Obtido para o período 1981-2010.....24
- Figura 6.** Scree plot do número de modos retidos na análise de componentes principais.....25
- Figura 7.** (a) Correlações entre a chuva acumulada na estação de cultivo de cada mesorregião e a produção observada, e (b) correlação entre a produtividade prevista com modelo de ACC e observada. Para o tamanho da amostra, 30 anos, todas as correlações acima de 0,4 são estatisticamente significativas de acordo com o teste t-student.....26
- Figura 8.** Produção observada (linha azul) e simulada com o modelo de ACC (linha vermelha), para o período 1981-2010, para as mesorregiões do Maranhão: (a) norte maranhense, (b) centro maranhense, (c) oeste maranhense, (d) leste maranhense e (e) sul maranhense.....28
- Figura 9.** Mesmo da Figura 8, mas para as mesorregiões do Piauí: (a) norte piauiense, (b) centro-norte piauiense, (c) sudoeste piauiense e (d) sudeste piauiense.....29
- Figura 10.** Mesmo da Figura 8, mas para as mesorregiões do Ceará: (a) norte (b) metropolitana de Fortaleza, (c) noroeste, (d) sertão, (e) centro-sul, (f) Jaguaribe e (g) sul cearense.....30
- Figura 11.** Mesmo da Figura 8, mas para as mesorregiões do Rio Grande do Norte: (a) oeste, (b) central, (c) agreste e (d) leste potiguar.....31
- Figura 12.** Mesmo da Figura 8, mas para as mesorregiões da Paraíba: (a) sertão, (b) Borborema, (c) agreste e (d) mata paraibana.....32

Figura 13. Mesmo da Figura 8, mas para as mesorregiões de Pernambuco: (a) sertão, (b) vale do São Francisco, (c) agreste, (d) mata e (e) metropolitana de Recife.....	33
Figura 14. Mesmo da Figura 8, mas para as mesorregiões de Alagoas: (a) sertão, (b) agreste e (c) leste alagoano.....	34
Figura 15. Mesmo da Figura 8, mas para as mesorregiões de Sergipe: (a) sertão, (b) agreste e (c) leste sergipano.....	35
Figura 16. Mesmo da Figura 8, mas para as mesorregiões da Bahia: (a) extremo oeste, (b) vale do São Francisco, (c) nordeste, (d) centro-norte, (e) metropolitana de Salvador, (f) centro-sul e (g) sul da Bahia.....	36
Figura 17. Desvio médio da produção em relação à média do período 1981-2010 de anos classificados sob a influência de Dipolo do Atlântico negativo e (a) Pacífico negativo, (b) Pacífico neutro e (c) Pacífico positivo.....	38
Figura 18. Desvio médio da produção em relação à média do período 1981-2010 de anos classificados sob a influência de Dipolo do Atlântico neutro e (a) Pacífico negativo, (b) Pacífico neutro e (c) Pacífico positivo.....	38
Figura 19. Desvio médio da produção em relação à média do período 1981-2010 de anos classificados sob a influência de Dipolo do Atlântico positivo e (a) Pacífico negativo, (b) Pacífico neutro e (c) Pacífico positivo.....	39

LISTA DE TABELAS

Tabela 1. Mesorregiões do NEB e respectivo semestre chuvoso.....**18**

Tabela 2. Preditor X e respectivos semestres mais chuvosos e Preditado Y com as respectivas séries de produtividade de cada mesorregião.....**21**

Tabela 3 - Para cada mesorregião, valores de correlações (r) obtidas da comparação direta chuva acumulada x produção observada, e a partir da produção simulada pelo modelo de ACC e observada. Valores em negrito destacam a maior r obtida.....**26**

Tabela 4 - Anos compostos classificados de acordo com as definições dos eventos climáticos observados nos oceanos Pacífico e Atlântico. DIP: dipolo do Atlântico; Pac: Pacífico; Neg: negativo; Neu: neutro; Pos: positivo.....**37**

LISTA DE ABREVIATURAS E SIGLAS

NEB	Nordeste Brasileiro
ACC	Análise de Correlação Canônica
AMJJAS	Abril a Setembro
CC	Cargas Canônicas
CCC	Cargas Canônicas Cruzadas
CPT	Climate Predictability Tool
ENOS	El Niño-Oscilação Sul
FMA	Fevereiro, Março e Abril
FOE	Funções ortogonais empíricas
hPa	Hectopascal
IBGE	Instituto Brasileiro de Geografia e Estatística
INMET	Instituto Nacional de Meteorologia
JFMAMJ	Janeiro a Junho
m	metros
MATOPIBA	Maranhão, Tocantins, Piauí e Bahia
MCG	Modelo de Circulação Geral
MJJ	Maior, Junho e Julho
mm	Milímetro
NCEP	National Centers for Environmental Prediction Climate Forecast System
NDJ	Novembro, Dezembro e Janeiro
°C	Celsius
ONDJFM	Outubro a Março
SIDRA	Banco de Dados Estatístico do Sistema de Recuperação Automática
TSM	Temperatura da Superfície do Mar
VC	Variáveis Canônicas
ZCIT	Zona de Convergência Intertropical

APRESENTAÇÃO E JUSTIFICATIVA

Este é a defesa da dissertação do discente Ivens Coelho Peixoto, portador do número de Matrícula UFAL nº 2019102330, aluno regular do Programa de Pós-Graduação em Meteorologia (PPGMET), do Instituto de Ciências Atmosféricas (ICAT), vinculado a Universidade Federal de Alagoas (UFAL).

A pesquisa possui o título: POTENCIAL PREDITIVO DA PRODUTIVIDADE DO MILHO NAS MESOREGIÕES DO NORDESTE BRASILEIRO, sob a orientação do Prof. Dr. Fabrício Daniel dos Santos Silva, pertence à linha de pesquisa: Agrometeorologia.

Este documento refere-se as atividades de pesquisa executadas pelo discente desde março de 2019, quando este deu início às suas atividades no PPGMET-ICAT/UFAL, até sua defesa em agosto de 2021.

A Região Nordeste é formada por 9 unidades de federação: Alagoas (AL), Bahia (BA), Ceará (CE), Maranhão (MA), Paraíba (PB), Pernambuco (PE), Piauí (PI), Rio Grande do Norte (RN) e Sergipe (SE) sendo a segunda região com maior população no país, com aproximadamente 56,1 milhões de habitantes em uma área com cerca de 1.554.291,6 km². Inserido nessas federações existem 42 mesorregiões, nas quais a agricultura possui grande relevância. Em uma região caracterizada por eventos meteorológicos adversos, estudar as relações entre a variabilidade pluviométrica e as safras agrícolas torna-se de fundamental importância para tomadas de decisões no setor agrícola. Neste sentido esta pesquisa terá como base a relação da produtividade x precipitação, sendo apresentado o potencial preditivo das safras de milho a partir de séries temporais de precipitação. O software utilizado para realizar os cálculos matemáticos foi o CPT (Climate Predictability Tool).

SUMÁRIO

LISTA DE ILUSTRAÇÕES.....	3
LISTA DE TABELAS.....	4
APRESENTAÇÃO E JUSTIFICATIVA	5
1. INTRODUÇÃO.....	8
1.1. OBJETIVOS.....	9
1.1.1. Geral.....	9
1.1.2. Específicos.....	9
2. REVISÃO BIBLIOGRÁFICA.....	10
2.1. ANÁLISE DE CORRELAÇÕES CANÔNICAS (ACC).....	10
2.1.1. ACC APLICADA A AGRICULTURA.....	10
2.1.2. ACC APLICADA A PREVISÃO CLIMÁTICA.....	11
2.2. CLIMA DA REGIÃO NORDESTE DO BRASIL.....	13
2.3. MILHO E INFLUÊNCIA DO CLIMA NA PRODUÇÃO.....	15
3. MATERIAIS E MÉTODOS.....	17
3.1. DADOS E ÁREA DE ESTUDO	17
3.2. ANÁLISE DE CORRELAÇÕES CANÔNICAS (ACC).....	20
3.3. SOFTWARE CPT E MODELO DE PREVISÃO.....	22
4. RESULTADOS E DISCUSSÃO.....	24
4.1. Resultados obtidos pelo modelo de ACC.....	24
4.2. Resultados por Estado – Maranhão	27
4.3. Resultados por Estado – Piauí	28
4.4. Resultados por Estado – Ceará	29
4.5 Resultados por Estado – Rio Grande do Norte	30
4.6. Resultados por Estado – Paraíba	31
4.7 Resultados por Estado – Pernambuco	32
4.8. Resultados por Estado – Alagoas e Sergipe.....	33
4.9. Resultados por Estado – Bahia	35
4.10. Interação Oceano-Atmosfera x Produção	36
5. CONCLUSÕES.....	39
7. REFERENCIAS BIBLIOGRAFICAS.....	40

1. INTRODUÇÃO

De acordo com o acompanhamento da safra de grãos brasileira realizada pela CONAB para a temporada 2019/2020, a estimativa foi de uma produção em 102,3 milhões de toneladas (CONAB, 2020), o milho inserido entre as principais commodities agrícolas brasileiras.

O cultivo do milho no Brasil acontece desde o descobrimento, originário da América era o principal suprimento da dieta dos índios. Com a chegada dos portugueses o aumento do seu consumo foi incorporado por novos produtos à base de milho. Fonte de energia, traz em sua composição vitaminas A e do complexo B, proteínas, gorduras, carboidratos, cálcio, ferro, fósforo e amido (ABIMILHO, 2019). Os maiores produtores mundiais de milho são os Estados Unidos (~345 milhões de toneladas), a China (~224 milhões de toneladas) e o Brasil (~81 milhões de toneladas). A região Centro-Oeste do Brasil é a maior produtora de milho (~42 milhões de toneladas). O estado do Mato Grosso do Sul (MS) é um dos maiores produtores de milho da região, com uma produção e produtividade média de 7,3 milhões de toneladas e 4,8 mil kg/ha (CONAB, 2018).

No Brasil o milho tem sido o segundo grão mais produzido e exportado. Este cereal é o principal componente utilizado na produção de suplementação animal, destinado a um dos principais segmentos da exportação brasileira, que é a cadeia produtiva de proteína animal (Souza et al, 2018).

Assumindo papel importante no meio socioeconômico em todo o Brasil, a cultura do milho pode ser utilizada tanto na alimentação humana como na dieta de vários animais (Devide et al., 2009). Segundo Garnett e Khandekar (1992), o impacto socioeconômico na produção é mais intenso em áreas onde ocorre grandes alterações nas condições climáticas, desta maneira entende-se que a produção varia consideravelmente de ano para ano.

A água é fator crucial para o desenvolvimento da planta de milho, cujo déficit é um dos principais causadores de queda da produtividade (Barros e Calado, 2014). A necessidade hídrica, a temperatura e a radiação solar são variáveis que interferem diretamente no período de crescimento, que atinge o máximo a partir da disponibilidade ideal destas variáveis, facilitando que a cultura alcance sua capacidade máxima de produtividade. Em condições tropicais, de acordo com a menor variação da temperatura e do comprimento do dia, a distribuição de chuvas é que geralmente determina a melhor época de semeadura (EMBRAPA, 2010).

No Nordeste do Brasil (NEB) ainda prevalece na maioria das mesorregiões o cultivo do milho via agricultura de subsistência, com pouca ou nenhuma mecanização, e baixo potencial tecnológico. Associada a alta variabilidade interanual da pluviometria, concentrada climaticamente em poucos meses e marcada pela variação espaço-temporal, a prática agrícola constitui-se numa atividade de alto risco, muitas vezes fadada a perdas totais da safra ou a baixa produtividade (Martins et al, 2018). Cenários de mudanças climáticas para a região, com diminuição da chuva acumulada e aumento da evapotranspiração, inspiram ainda mais preocupação para os rendimentos futuros (Martins et al, 2019).

Em 2012 e 2018, o NEB atravessou uma de suas maiores secas, tanto em período de duração, quanto em magnitude e intensidade (Marengo et al, 2016; Cunha et al, 2015; Cunha et al, 2018; Cunha et al, 2019; Alvalá et al, 2017; Martins et al, 2018). Costa et al

(2020) mostraram que índices de extremos climáticos indicam redução das chuvas em boa parte do Nordeste nas últimas décadas, e Rocha Júnior et al (2020), evidenciaram que todas as áreas do Nordeste são altamente susceptíveis ao retorno de secas em diferentes escalas.

Nas últimas décadas, uma parte do NEB que compreende o sul dos Estados do Maranhão e Piauí, e oeste da Bahia, tem experimentado uma revolução na produtividade de grãos, por meio de uma agricultura com forte incremento tecnológico em práticas de manejo e irrigação. Essa região é conhecida por MATOPIBA, acrônimo das siglas dos Estados que a compõem, Maranhão, Tocantins, Piauí e Bahia (Salvador et al, 2018).

No entanto o MATOPIBA é uma exceção e a maior parte da produção agrícola do NEB é de subsistência, cujas perdas frequentes levaram o Governo Federal a instituir o Programa Garantia-Safra, que provê ao agricultor familiar uma compensação financeira quando os municípios decretam perdas agrícolas geralmente devido ao déficit hídrico no respectivo ano.

De acordo com Alves (2012), as análises complementares sugeriram que a diminuição da precipitação no NEB esteve mais diretamente associada ao ciclo El Niño-Oscilação Sul (ENOS) e ao dipolo de Temperatura da Superfície do Mar (TSM) no Atlântico tropical.

Diretamente dependente da variabilidade pluviométrica, a intensidade da perda associada a safra é tão maior quanto maior for a escassez de chuvas. Desta forma, uma ferramenta útil a processos de tomadas de decisão na agricultura seria uma boa previsão da safra a partir de uma previsão das chuvas acumuladas no período de crescimento das culturas. Desta forma, o objetivo geral desse estudo é analisar e investigar o potencial preditivo da produtividade da cultura do milho de todas as mesorregiões do NEB.

1.1. OBJETIVOS

1.1.1. OBJETIVO GERAL

Analisar a potencial preditivo da produtividade do milho em mesorregiões do NEB por meio da relação entre a produtividade histórica e a precipitação acumulada no semestre chuvoso, utilizando a técnica de Análise de Correlações Canônicas (ACC).

1.1.2. OBJETIVOS ESPECÍFICOS

1. Correlacionar e identificar os períodos de maior influência das chuvas na produtividade do milho das mesorregiões do NEB.
2. Calibrar um modelo de previsão de safras a partir de uma técnica de análise multivariada: análise de correlações canônicas.
3. Quantificar a influência das diferentes fases do ENOS e do dipolo do atlântico na distribuição das chuvas nas mesorregiões do NEB e impactos na produtividade do milho.

2. REVISÃO BIBLIOGRAFICA

2.1. ANÁLISE DE CORRELAÇÕES CANÔNICAS (ACC)

A Análise de Correlações Canônicas (ACC) é um método linear multivariado (Hotelling,1936) conhecido sobretudo pelas suas qualidades teóricas, pois ele engloba outros métodos de estatísticas multivariada, usado para comparar dois conjuntos de dados: um independente X , também conhecido como variáveis explanatórias, e outro dependente Y , também conhecido como variáveis de resposta, compostos por um número p das variáveis X_i e q variáveis Y_i , respectivamente.

É um método utilizado com a finalidade de identificar a influência de uma variável sobre outra variável, a fim de encontrar uma melhor combinação linear e a máxima correlação entre as duas variáveis. Possui como vantagem em relação a regressão linear múltipla a possibilidade de estudar as inter-relações entre conjuntos de múltiplas variáveis dependentes e múltiplas variáveis independentes, podendo prever simultaneamente múltiplas variáveis dependentes a partir de múltiplas variáveis independentes (Wilks, 2011; Singh et al. 2012).

A aplicabilidade dessa técnica é ampla, desde aplicação ao fluxo de tráfego veicular (Bogo et al., 2010), influência das variáveis meteorológicas na qualidade industrial do trigo (Miloca et al., 2007), indicadores socioeconômicos (Proque, 2019), identificação de preferências virais (Gumus et al., 2012).

No entanto, a ACC ganhou destaque nas últimas décadas por sua aplicabilidade a previsão climática, principalmente em relação à previsão sazonal. Repelli e Alves (1996) aplicaram a ACC para prever a variabilidade sazonal das chuvas no semiárido nordestino, em um modelo cujo preditor foi a Temperatura da Superfície do Mar (TSM). A influência da TSM nas chuvas da região Nordeste do Brasil já é conhecida há muito tempo (Walker, 1928), mas estudos recentes vieram a comprovar isso de forma mais ampla (Ambrizzi et al., 2002; Lucio et al., 2010; Zakaria e Hossain,2019; Gubler et al., 2020). Por extensão, setores como agricultura e recursos hídricos de áreas cuja relação TSM-precipitação é mais direta, como o Nordeste brasileiro, podem ser beneficiados com o desenvolvimento de modelos usando ACC para previsão de safras, de vazões, entre outras aplicações, melhor detalhadas a seguir.

2.1.1. ACC APLICADO À AGRICULTURA

De acordo com o estudo Esquivel (2018) na Colômbia, a ACC foi utilizada para avaliar a precipitação sazonal do local, sua previsibilidade e habilidade de previsão das culturas arroz, milho e feijão. A precipitação prevista foi a principal variável meteorológica utilizada na pesquisa junto com a TSM observada e a modelada. A TSM foi modelada pelos dados da National Centers for Environmental Prediction Climate Forecast System (NCEP). Os resultados foram consistentes entre as previsões, podendo oferecer ótimas informações para as tomadas de decisões referentes a agricultura nas áreas estudadas.

Ferreira et al (2006), analisaram a relação entre a Temperatura da Superfície do Mar (TSM) e a produção de soja no Paraná por meio da ACC. Para um período de análise de 16 anos, entre 1990 a 2005, os autores verificaram um percentual de explicação da variância da produção em torno de 75% relacionada as TSMs do Oceano Atlântico Sul (23° - 30°S, 49° - 39°W) e em torno de 62% associada as TSMs do Oceano Pacífico tropical na região do Niño 3 (5°N - 5°S, 150° - 90°W), apresenta que a variabilidade do Oceano Atlântico próximo ao Estado influencia mais na produtividade do que determinadas fases ENOS ocorridas no Oceano Pacífico. A ACC entre as TSMs dos Oceanos Pacífico e Atlântico Sul e a produtividade de soja no Paraná apresentou melhores correlações nos meses que correspondem ao enchimento de grãos da soja (dezembro a abril).

Alves et al (2017) avaliaram os efeitos da multicolinearidade na representatividade da fase de maturação do milho para a safra de 2009/2010 em uma área experimental na Universidade Federal de Santa Maria. Inicialmente foi estudada uma matriz de correlações a partir de vinte e nove variáveis fenotípicas, entre variáveis proteico-nutricionais, onze variáveis agronômicas e seis variáveis energético-nutricionais. Sem a eliminação de variáveis auto correlacionadas, a ACC superestimou a variabilidade dos coeficientes canônicos, enquanto a eliminação de variáveis é um método eficiente para contornar a multicolinearidade na ACC.

A relação entre características locais (propriedades topográficas e físicas do solo) com o rendimento e desenvolvimento do dossel da soja foi investigada com a ACC em um campo de produção no Estado americano do Illinois nas temporadas de 2000 e 2001 (Martín et al, 2005). A ACC permitiu identificar que características locais eram consistentemente correlacionadas com o desenvolvimento da soja, principalmente a matéria orgânica, o pH e a condutividade elétrica do solo. Variáveis locais como teores de fósforo e potássio no solo não estavam correlacionadas com as características locais. As estruturas espaciais comuns em pares das variáveis canônicas confirmaram a relação entre as propriedades locais e o rendimento da soja, podendo ser mais amplamente utilizada para explorar as relações das plantas no solo em outros estudos de campo.

Para o rendimento da cana de açúcar no Estado de Alagoas, Silva et al (2007) aplicaram a ACC para verificar as combinações lineares cujas correlações seriam mais elevadas entre diferentes características agronômicas e fisiológicas e a produção de cana por hectare. A ACC mostrou que o aumento da produção de cana por hectare está relacionado com o número de touceiras por parcela, número de colmos por touceira e diâmetro do colmo em plantas baixas.

2.1.2. ACC APLICADO À PREVISÃO CLIMÁTICA

Previsões sazonais fornecem uma visão de longo prazo das mudanças no sistema climático terrestre para períodos de algumas semanas a meses, a partir de resultados de mudanças previsíveis em alguns dos componentes de variação lenta do sistema. Como exemplo temos a Temperatura da Superfície do Mar (TSM), que varia lentamente e tem impacto decisivo em condições atmosféricas locais e remotas. Essas mudanças lentas, que podem ser monitoradas, são a essência de todas as previsões de longo alcance.

Variáveis como a TSM são essenciais para o entendimento do comportamento climático no futuro próximo. No entanto, interações complexas e não lineares impõem limitações às previsões climáticas em todas as escalas, de semanas a meses, e trimestres, com isso impossibilitando a implementação de um bom sistema de previsão.

Neste sentido, a ACC tem sido uma ferramenta útil ao longo das últimas décadas para maximizar a previsão climática. Chu e He (1994) utilizaram ACC para prever as chuvas de inverno no Havaí. A ACC foi superior a outros métodos de previsão utilizados, na comparação histórica entre simulações e observações, com esses resultados indicando que as chuvas de inverno no Havaí poderiam ser previstas com um grau de sucesso satisfatório com até duas estações de antecedência, sendo utilizado como preditores o índice de oscilação sul observado no verão e os quatro modos principais de variabilidade da pressão ao nível do mar sobre o Pacífico Norte.

A ACC foi usada para a previsão da precipitação do bimestre maio-junho em oito estações ao longo da ilha de Taiwan, com a preditora sendo a TSM do bimestre anterior novembro-dezembro sobre o Oceano Pacífico ($50^{\circ}\text{N} \pm 40^{\circ}\text{S}$, $120^{\circ}\text{E} \pm 90^{\circ}\text{W}$). Funções ortogonais empíricas (FOE) foram utilizadas para reduzir a dimensão dos dados preditores, e um procedimento de validação cruzada foi usada para estimar a habilidade do modelo de ACC, calibrado no período 1956-1985 e usado para prever as chuvas de 1986 a 1995. Os resultados mostraram uma resposta comum na aplicação de modelos de previsão com a ACC, que existia maior habilidade em algumas estações do que em outras, mas que de forma geral o modelo demonstrava uma habilidade média que o tornava interessante para fins de previsão (Chu, 1998).

Landman e Mason (1999) dividiram a África do Sul em cinco regiões homogêneas e usaram as variáveis canônicas para estudar a variabilidade e previsibilidade das chuvas de verão na África do Sul, para os trimestres outubro-novembro-dezembro e janeiro-fevereiro-março, a partir da TSM em escala global. Foi encontrada uma destreza modesta (correlações $> 0,5$) no interior e parte ocidental do País, com as contribuições mais importantes oriundas do Oceano Pacífico equatorial, com previsibilidade mais fraca na porção equatorial dos Oceanos Atlântico e Índico.

Toscano e Reisen (2000), demonstraram que a ACC pode ser usada para identificar a estrutura de modelos de séries temporais lineares multivariados da família ARMA. Neste sentido, Lúcio et al (2010) implementaram para o Brasil um sistema de previsão climática sazonal da precipitação e temperatura baseado na combinação de resultados de previsões de modelos ARIMA (Box e Jenkins, 1976), de suavização exponencial de Holt-Winters (Holt, 1957; Winters, 1960), e de ACC (Barnston e Smith, 1996).

Com estudos prévios que demonstraram o potencial da ACC para fins de previsão climática, Chowdhury et al (2007) tiveram como objetivo operacionalizar um modelo estatístico de ACC para previsão do nível do mar nas ilhas americanas do Oceano Pacífico, com vários meses de antecedência. Como potenciais preditores estariam as fases do ENOS associadas as TSMs do Oceano Pacífico tropical, com os resultados indicando que durante a fase quente, El Niño, havia baixa no nível do mar e durante La Niña, havia alta do nível do mar, com fortes correlações entre a variabilidade do nível do mar e a variação nas TSMs do Pacífico tropical.

Juneng e Tangang (2008) usaram modelos de previsão baseados em ACC para as chuvas sazonais na Malásia, com os cinco preditores: as chuvas em estações anteriores, a TSM local sobre o setor oeste do Pacífico, TSM quase global, pressão ao nível do mar e altura geopotencial em 700hPa, de quatro períodos preditivos de três meses para projetar campos de previsão que variam de 0 a 9 meses após um único período de previsão de 3 meses. Os resultados mostraram que o modelo apenas com a TSM quase global produziu as melhores previsões em termos de destreza confrontada às observações, com o inverno sendo a estação cujo modelo apresentou a melhor habilidade de previsão. Busuioc et al (2008) usaram um modelo de redução de escala baseado em ACC para previsão de três índices de precipitação de inverno na região de Emilia-Romagna, na Itália, utilizam como variáveis preditoras a pressão ao nível do mar, a instabilidade potencial e a umidade específica. Cada preditor demonstrou ter maior habilidade em casos específicos para cada índice analisado, que foram o número de eventos que excedem o percentual 90 de longo prazo, a intensidade diária simples da chuva e o número máximo de dias secos consecutivos para sub-regiões homogêneas identificadas via cluster.

Lim et al (2012) propuseram uma melhoria ao método convencional da ACC para previsão climática sazonal, aplicada a previsão para o verão boreal (junho-julho-agosto) nas escalas global e regional a partir de um hindcast de 29 anos (1979-2007), a fim de corrigir vieses de um Modelo de Circulação Geral (MCG). Este sistema operacional de previsão sazonal pertence a Administração Meteorológica da Coreia do Sul e demonstra uma previsão climática sazonal mais precisa.

2.1 CLIMA DA REGIÃO NORDESTE DO BRASIL

Segundo Prates et al (1986), o regime de chuvas ainda se constitui no principal fator limitador das safras. Estudos recentes mostram que este fator ainda não foi contornado, principalmente em áreas dependentes exclusivamente da agricultura de sequeiro (Martins et al, 2017). A região Nordeste é afetada em alta frequência por adversidades climáticas, com destaque para a seca. Silva et al (2013) estudaram a mudança de padrão climático entre os anos de 2011, chuvoso, e 2012, extremamente seco. No entanto, 2012 marcou o início de uma continuidade de anos secos consecutivos que, para muitos autores, constituiu-se num dos mais intensos ciclos de seca contínua já verificadas no Nordeste (Cunha et al, 2015; Alvalá et al, 2017; Martins et al, 2018a; Martins et al, 2018b; Cunha et al, 2018; Marengo et al, 2018; Cunha et al, 2019).

As chuvas mostram uma acentuada variabilidade espacial, sazonal e interanual. De acordo com a concentração de chuvas, três áreas diferem no NEB: o norte, com médias anuais que variam de 1000 a 1800 mm/ano, do interior dos estados de Ceará e Piauí até a porção mais úmida da região amazônica do Maranhão; 600 mm a 1200 mm no centro-oeste; e leste com aproximadamente 1200 a 1400 mm/ano (Alves et al, 1992; Rao et al, 1993; Hastenrath et al, 1993; Costa et al, 2020).

De acordo com Rocha Júnior et al (2019), a porção centro-oeste do NEB inclui a Bahia com exceção da costa norte, sul do Maranhão e Piauí, centro sul de Pernambuco e extremo oeste de Alagoas e Sergipe, com chuvas concentradas no trimestre novembro-

dezembro-janeiro (NDJ). As chuvas ocorrem devido à influência dos sistemas frontais do hemisfério sul e da zona de convergência do Atlântico Sul, bem como à ação de vórtices ciclônicos de altos níveis (Kousky 1979; Kousky e Gan, 1981; Costa et al, 2014; Cordeiro et al, 2018). O norte inclui o centro-norte do Maranhão, Piauí e Pernambuco, todo o Ceará, e oeste do Rio Grande do Norte e Paraíba, com chuvas concentradas em fevereiro-março-abril (FMA), influenciadas pela zona de convergência intertropical (Moura e Shukla, 1981; Hastenrath 1984; Hastenrath 2012; Carvalho et al, 2013), fortemente modulado pela temperatura da superfície do mar no Oceano Atlântico equatorial (Silva et al, 2013). O leste é composto pela faixa costeira do Rio Grande do Norte, Paraíba, Pernambuco, Alagoas, Sergipe e norte do litoral da Bahia, com o principal período chuvoso nos trimestre maio-junho-julho (MJJ), como consequência da atuação dos distúrbios ondulatórios de leste (Kayano e Andreoli, 2006; Gomes et al, 2015; Gomes et al, 2019).

Outros modos de variabilidade modulam as chuvas no NEB, com baixa frequência temporal, como a oscilação do Atlântico Norte, oscilação decadal do Pacífico, oscilação multidecadal do Atlântico e oscilação de Madden-Julian (Kousky e Kayano, 1994; Kayano e Andreoli, 2004; Kayano e Capistrano, 2014; Barreto et al, 2017).

Em estudo recente, da Rocha Júnior et al (2020) mostraram que a variabilidade das secas no NEB depende de vários fatores e não seguem necessariamente o mesmo comportamento, em investigação sobre a frequência e o período de retorno das secas. Com dados históricos de precipitação observada no NEB calcularam o índice de precipitação padronizado, e com testes de três famílias de cópulas arquemedianas, puderam observar que as secas mais frequentes estão concentradas no norte da região, mas com o NEB oriental experimentam as secas mais severas, com duração de 14 a 24 meses. O NEB como um todo mostra um período de retorno médio das secas de aproximadamente 24 meses, com o extremo sul apresenta um período de retorno superior a 35 meses, a faixa leste com o maior período de retorno, superior a 60 meses, e com o norte do NEB demonstram um menor período de retorno, em torno de 45 meses, sendo o setor com a maior frequência de secas intensas.

Dois fenômenos meteorológicos possuem grande relevância referindo-se ao clima do NEB: ENOS e o dipolo de temperatura da superfície do mar (TSM) no Atlântico tropical possuem forte influência na variabilidade climática do NEB. De acordo com diversos estudos na literatura têm mostrado que em anos de El Niño o NEB apresenta menos precipitação anual do que a climatologia e em anos de La Niña apresentam mais precipitação anual, sendo associados com as fases positivas e negativas do padrão de dipolo de TSM. Com a fase positiva deste padrão caracteriza-se com anomalias de TSM positivas nos setores norte do Atlântico tropical, com ventos e pressão ao nível do mar com anomalias, já na fase negativa do dipolo de TSM, estas características são contrárias (MOURA & SHUKLA, 1981; HASTENRATH, 1990; NOBRE & SHUKLA, 1996).

Segundo Oliveira e Kayano (2020), foi analisado na América do Sul os padrões de precipitação associados com os ENOS sendo representado pelo índice da TSM. Afim de investigar os efeitos da oscilação decenal do Pacífico, foram divididas em dois períodos para melhor acurácia nos resultados: fase fria (1948-1976) e fase quente (1976-2002).

Xavier (2003) correlacionou os episódios de eventos dos ENOS com a variação dos posicionamentos da Zona de Convergência Intertropical (ZCIT), a fim de obter valores das chuvas acumuladas nas principais bacias hidrográficas do Ceará durante a quadra chuvosa climatologicamente corresponde ao quadrimestre fevereiro-maio. Como resultado preliminar ficou nítido o papel das ocorrências de eventos ENOS no Pacífico, com relação à descida para o sul da ZCIT no Atlântico e, também, com as chuvas nas bacias.

2.2. MILHO E INFLUÊNCIA DO CLIMA NA PRODUÇÃO

O milho (*Zea mays* L.) é originário da América Central, em uma região entre o sul do México e o norte da Guatemala. É uma gramínea que pode atingir alturas entre 1,70 e 2.50m entre as fases de florescimento e maturação. É uma planta com grande adaptabilidade climática e pode ser cultivada desde o nível do mar até mais de 3000m de altitude. A temperatura ideal para o cultivo do milho se dá no limiar entre 24 e 30°C, suportando temperaturas médias noturnas acima de 12,8°C e médias diurnas acima de 19°C (Andrade e Abreu, 2007; Bergamaschi e Matzenauer, 2009).

Algumas fases são mais sensíveis à temperatura. Para germinar, o solo deve apresentar temperaturas entre 25 a 30°C. Temperaturas de solo inferiores a 10°C e superiores a 40°C podem inviabilizar o processo de germinação. Verões com temperatura média diária inferior a 19°C e noites com temperatura média inferior a 12,8°C não são recomendados para cultivo do milho. Por outro lado, temperaturas noturnas superiores a 24°C proporcionam um aumento da respiração, ocasionam uma diminuição da taxa de fotossíntese e consequente redução da produtividade. Temperaturas inferiores a 15°C retardam a maturação dos grãos (Sbrussi e Zucareli, 2014).

O conceito de Graus-Dia de desenvolvimento aplicado ao milho mostra que as exigências térmicas dos cultivares normais varia de 890 a 1200 graus dia, de 831 a 890 graus dia em cultivares precoces, e de 780 a 830 graus dia em cultivares superprecoces (Renato et al, 2013; Gaspar et al, 2015). Estas seriam as exigências calóricas referentes a uma evolução plena do cultivar de milho ao atingir todas as suas fases fenológicas desde a emergência da plântula até o momento da polinização, ou fase reprodutiva que dará início ao desenvolvimento do sabugo e enchimento dos grãos.

O milho é uma cultura de ciclo curto, e seu ciclo de vida pode variar, a depender da variedade, de 110 a 160 dias (Alvarenga et al, 2017), com as necessidades hídricas da cultura varia de 500 a 800mm de lâmina de água com boa distribuição desde a semeadura até o ponto de maturação fisiológica dos grãos, sendo as fases mais sensíveis ao déficit hídrico as de florescimento ou inflorescência, e de enchimento de grãos (Melo et al, 2010; Martins et al, 2019).

Podendo ser cultivado em regiões com índices pluviométricos que variam de 250mm a 5000mm no ano, e consomem média 600mm de água no seu ciclo de vida, o déficit hídrico é potencialmente danoso a cultura em qualquer de suas fases de desenvolvimento. A planta consome em média 2,5mm/dia nos estágios iniciais de crescimento, e de 5 a 7,5mm diários entre o espigamento e a maturação, no entanto sob

uma combinação de temperaturas muito altas e umidades relativas muito baixas, o consumo diário da planta pode chegar a 10mm (Radin et al, 2003).

Completam as exigências climáticas do milho sua sensibilidade ao fotoperíodo e a radiação solar. No Brasil os efeitos do fotoperíodo são insignificantes as variedades de milho cultivadas, e a radiação solar é essencial ao processo de fotossíntese para fixação de dióxido de carbono e produção de matéria seca. Redução na disponibilidade média da luminosidade solar em torno de 30 a 40% por dias consecutivos pode reduzir em 60% a produtividade da cultura (Schwerz et al, 2016).

O ciclo de vida do milho é dividido basicamente em quatro etapas principais, que seriam o Estágio de Desenvolvimento 01, compreendendo da germinação à emergência, com duração de 5 a 12 dias, a depender da umidade do solo e da temperatura do ambiente. o Estágio de Desenvolvimento 02, compreendendo da emergência ao florescimento feminino, com duração dependente do comprimento do ciclo do cultivar, sendo esta a etapa vegetativa do milho. O Estágio de Desenvolvimento 03, entre o florescimento e o espigamento com duração de no máximo 10 dias, e enfim o Quarto Estágio de Desenvolvimento, entre o espigamento e a maturação fisiológica, ou seja, a granação com duração de 40 a 60 dias (Bergamaschi e Matzenauer, 2009; Buske et al, 2019). No entanto, essas são apenas os quatro mais importantes estágios de desenvolvimento.

As características gerais da cultura do milho a coloca entre as mais propícias à agricultura de subsistência. Em condições normais de cultivo, a partir de cerca de 80 dias após a emergência das plantas, já se é possível a obtenção do “milho verde”, a base de alimentos humanos como milho cozido, pamonha, curau, bolos, etc. e de forragens com a parte aérea da planta disponibilizada diretamente aos animais ou ainda através de sua ensilagem, nesse sentido, possibilita a conservação de forragens a serem utilizadas em ocasiões de déficits alimentares. Os grãos de milho são considerados um dos produtos mais indispensáveis à alimentação humana.

No NEB, com exceção da região conhecida por MATOPIBA, acrônimo das siglas dos Estados que a compõem, sendo três no NEB, Maranhão, Piauí e Bahia (Salvador et al, 2017), boa parte do milho cultivado é produto da agricultura familiar, sob condições de sequeiro e com pouco ou nenhum acesso à tecnologia, com rendimento médio em quilogramas por hectare muito inferior a áreas com acesso à mecanização, cultivares com maior resistência a pragas e adversidades climáticas, e irrigação automatizada (Martins et al, 2014).

3. MATERIAIS E MÉTODOS

3.1. DADOS E ÁREA DE ESTUDO

O NEB está em uma região equatorial entre os paralelos 1-21°S e os meridianos 32-49°W. O NEB tem aproximadamente $1,6 \times 10^6$ km² de área, o que representa 18% do território brasileiro. Abrange nove estados: Maranhão (MA), Piauí (PI), Ceará (CE), Rio Grande do Norte (RN), Paraíba (PB), Pernambuco (PE), Alagoas (AL), Sergipe (SE) e Bahia (BA). Os nove Estados do NEB são subdivididos em 42 mesorregiões, como ilustra a Figura 1. A vegetação característica de toda região costeira é a Mata Atlântica. A vegetação presente na porção central do NEB (região semiárida) é a Caatinga. A região de transição entre a Caatinga e a Mata Atlântica é chamada de Agreste. Encontrada no extremo noroeste da região, no estado de MA, predomina a vegetação típica da floresta amazônica, enquanto no sul do estado de MA e PI, e a oeste do estado de BA, prevalece a vegetação do Cerrado.

Para cada mesorregião, foi identificado o semestre mais chuvoso, mostrado na Figura 1. Esta tarefa simples, mas essencial à pesquisa, foi realizada a fim de simular a produtividade do milho em cada mesorregião considerando um ciclo médio de 120 dias para a cultura, não incorrendo em risco cometer o erro de não adequar o período chuvoso ao período de plantio. Como exemplo, para uma determinada mesorregião onde o semestre mais chuvoso seja janeiro a junho, o ciclo de 120 dias da cultura ou quatro meses, em média, estaria compreendido nele.

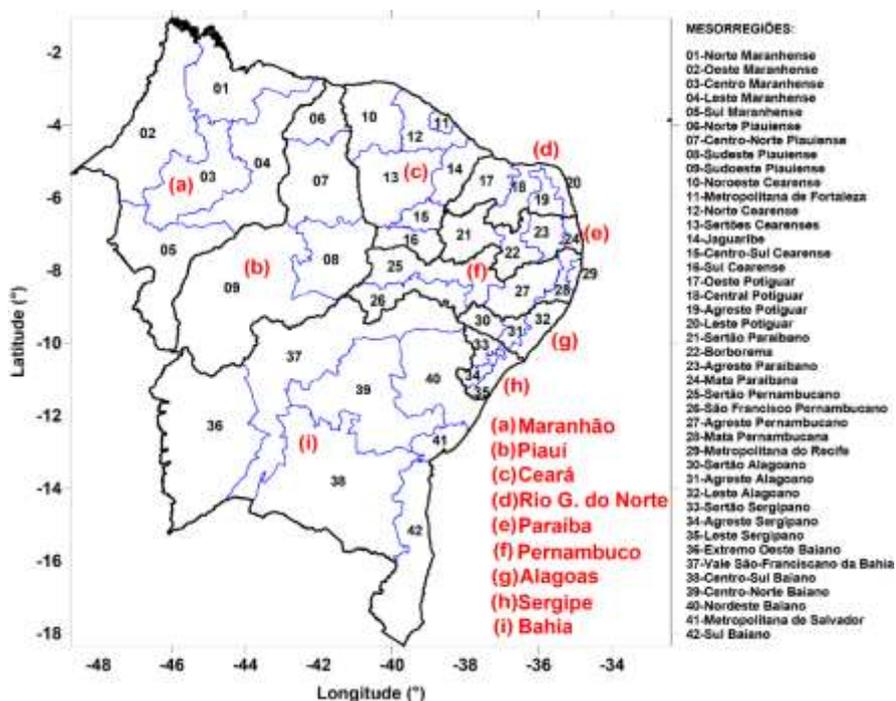


Figura 1. Mapa da região Nordeste do Brasil identificando os nove Estados, (a) Maranhão, (b) Piauí, (c) Ceará, (d) Rio Grande do Norte, (e) Paraíba, (f) Pernambuco, (g) Alagoas, (h)Sergipe e (i) Bahia, e identificando as 42 mesorregiões, numeradas entre os Estados. (Autor. 2021)

Tabela 1 - Mesorregiões do NEB e respectivo semestre chuvoso.

Mesorregião	Semestre chuvoso
Norte Maranhense Oeste Maranhense Central Maranhense Leste Maranhense Norte Piauiense Centro Norte Piauiense Sudeste Piauiense Noroeste Cearense Metropolitana de Fortaleza Norte Cearense Sertões Cearenses Jaguaribe Centro-Sul Cearense Sul Cearense Oeste Potiguar Central Potiguar Sertão Paraibano Borborema Sertão Pernambucano São-Francisco Pernambucano Vale São Franciscano da Bahia Centro Norte Baiano	Janeiro a Junho
Sul Maranhense Sudoeste Piauiense Extremo Oeste Baiano Centro Sul Baiano	Outubro a Março
Agreste Potiguar Leste Potiguar Agreste Paraibano Mata Paraibana Agreste pernambucano Mata Pernambucana Metropolitana do Recife Sertão Alagoano Agreste Alagoano Leste Alagoano Sertão Sergipano Agreste Sergipano Leste Sergipano Sul Baiano Nordeste baiano Metropolitana de Salvador	Abril a Setembro

Neste estudo, foram utilizadas séries temporais de precipitação mensal de 97 estações meteorológicas convencionais do Instituto Nacional de Meteorologia (INMET), de 1961 ao presente. A localização das estações pode ser vista na Figura 2.

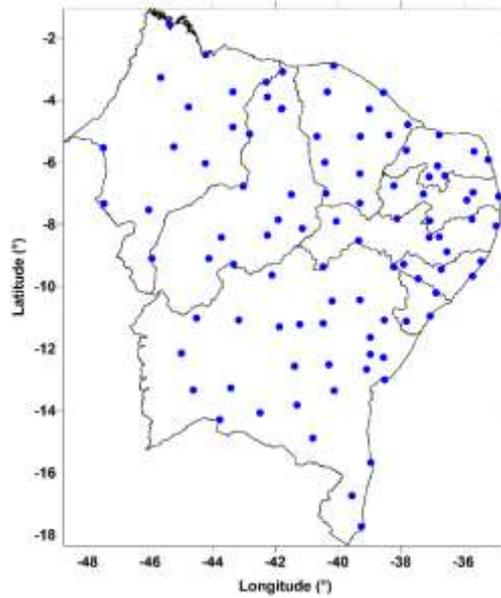


Figura 2. Distribuição geográfica das 97 estações meteorológicas convencionais no NEB.

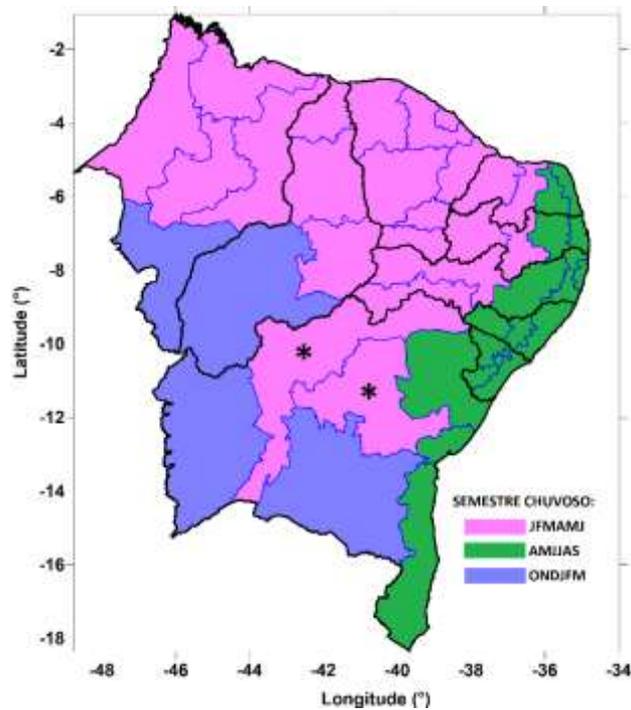


Figura 3. Semestre chuvoso de cada mesorregião do NEB.

Os dados de produtividade foram coletados do Banco de Dados Estatístico do Sistema de Recuperação Automática (SIDRA) do Instituto Brasileiro de Geografia e Estatística (IBGE), para o período de 1974 a 2018.

No entanto, a base de dados pluviométrica e de produtividade foi trabalhada para um período em comum a fim de eliminar problemas de continuidade observados no início das séries de produtividade do milho para cada mesorregião, sendo utilizado uma homogeneização dos mesmos sem necessidade de preenchimento de falhas. O período em comum de dados foi de 1981 a 2010, 30 anos, mesmo período utilizado para gerar as climatologias das chuvas de cada mesorregião e identificar os semestres mais chuvosos.

3.2. ANÁLISE DE CORRELAÇÕES CANÔNICAS (ACC)

Até recentemente, a ACC era uma técnica estatística relativamente desconhecida. Como ocorre com quase todas as técnicas multivariadas, a disponibilidade de programas computacionais facilitou sua crescente aplicação em problemas de pesquisa. Ela é particularmente útil em situações nas quais múltiplas medidas de resultados devem estar disponíveis, como nas previsões climáticas ou de safras em múltiplas estações (Díaz e Villegas, 2015). A ACC é tida como o modelo geral no qual muitas outras técnicas multivariadas são baseadas, pois ela pode utilizar tanto dados métricos quanto não-métricos para variáveis dependentes (X) ou independentes (Y), compostas de um número p de variáveis x_i e um número q de variáveis y_i , respectivamente.

Na ACC, criam-se combinações lineares x^* e y^* , chamadas variáveis canônicas (VC), com pelo menos duas variáveis de cada conjunto WILKS, D.S.(2011):

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

os vetores α e β devem maximizar a correlação entre x^* e y^* , e cada VC deve conter variância e não estar correlacionada com outras VC:

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

onde r_c é a correlação canônica. O cálculo das VC é realizado a partir das matrizes de variância e de covariância [S_c] das variáveis iniciais X e Y :

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

[S_{xx}] e [S_{yy}] são as matrizes de variância e covariância das p variáveis em X e as q variáveis em Y ; [S_{xy}] e [S_{yx}] são as matrizes de covariância entre os elementos de X e os elementos de Y . As correlações canônicas r_c entre as diferentes VC são dadas pela raiz quadrada dos valores inteiros, diferentes de zero nas matrizes.

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

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

e os vetores α e β serão os respectivos vetores típicos das matrizes que satisfazem:

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

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

Os valores de α e β revelam quais variáveis possuem a maior força explicativa dentro da correlação e são importantes quando se está construindo um modelo preditivo (Wilks, 2011; Singh et al, 2012). Além de α e β na ACC, também são calculadas as cargas canônicas (CC) e as cargas canônicas cruzadas (CCC). As CC permitem conhecer a contribuição de cada variável observada x_i e y_i para sua respectiva VC x^* e y^* . As CC independentes são as correlações lineares entre x_i e x^* , e as CC dependentes entre y_i e y^* . As CCC dão informações mais significativas da relação entre as variáveis observadas e as novas VC (Katz et al, 2003). As CCC independentes são as correlações lineares entre x_i e y^* e as CCC dependentes entre y_i e x^* . Finalmente, na ACC é calculado o coeficiente de redundância, que permite estabelecer o percentual de variância explicada no conjunto de variáveis dependentes, a partir do conjunto de variáveis independentes (Katz et al, 2003). A ACC foi escolhida para ser o método de previsão desta pesquisa por ser um dos métodos menos dependentes da periodicidade dos fenômenos climáticos, e como serão analisados resultados que evoluem em distintas escalas de tempo, utilizar esta metodologia mostra-se apropriado aos objetivos da pesquisa.

Esta pesquisa implementa a ACC como a ferramenta para relacionar a precipitação acumulada semestralmente e a produtividade observada do milho, em quilogramas por hectare, nas mesorregiões do NEB com histórico de produtividade disponível no IBGE. As séries temporais das estações meteorológicas foram eleitas por conter dados na mesma escala de tempo da produtividade, sem dados faltantes, para o período de 1981 a 2010.

Os dados mensais de chuva foram organizados como séries temporais acumuladas semestralmente para os seguintes períodos: janeiro a junho (JFMAMJ), outubro a março (ONDJFM) e abril a setembro (AMJJAS), ou seja, cada série temporal mensal contínua de precipitação se divide em três séries de acumulados semestrais. Segundo Stevens e Ruscher (2014), esta forma de organizar os dados maximiza a possibilidade de encontrar relações entre a precipitação acumulada e a produtividade da cultura em cada ano utilizado para *hindcast*, entre 1981 a 2010.

Tabela 2. Preditor X e respectivos semestres mais chuvosos e Preditado Y com as respectivas séries de produtividade de cada mesorregião. (Autor:2021).

Preditor (x^*)	Preditando (y^*)
Chuva acumulada do semestre JFMAMJ	Produtividade das mesorregiões 
Chuva acumulada do semestre AMJJAS	Produtividade das mesorregiões 
Chuva acumulada do semestre ONDJFM	Produtividade das mesorregiões 

O software utilizado para realizar os cálculos matemáticos foi o CPT (Climate Predictability Tool).

3.3 SOFTWARE CPT E MODELO DE PREVISÃO

O software CPT (Climate Predictability Tool) foi desenvolvido pelo International Research Institute for Climate and Society (IRI, 2006). Hoje, o software se encontra em sua versão 17.4.4, é livre e sendo disponibilizado para as plataformas windows, linux e python.

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

Como já mencionado, a ACC é amplamente utilizada para gerar previsões climáticas operacionais (Mason e Tippett., 2017; Esquivel et al., 2018; Hossain et al., 2019). No CPT, a ACC pode ser usada de duas formas (ver a Figura 1 de Barnston e Tippett, 2017), a primeira é relacionar saídas brutas de modelos dinâmicos à observações, por exemplo, precipitação acumulada prevista de um mês/trimestre relativo a um período de referência passado (hindcast) com as observações reais desse período, e assim recalibrar e corrigir vieses nessas previsões, permitindo aplicar essa correção as futuras previsões dos modelos. A segunda forma, e utilizada nessa pesquisa, é construir um modelo de previsão puramente estatístico, relacionando um preditor a um preditando, em nosso caso, campos de precipitação observada com dados de produção do milho em mesorregiões do NEB. Esta metodologia é similar a previsão sazonal com ACC relacionando TSM (preditor) com a precipitação (preditando).

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

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

deriva das variáveis originais, convertendo-se a função temporal canônica do preditor em função temporal canônica do preditando.

Por fim, a equação preditiva é obtida para relacionar preditor ao preditando, ou X a Y, e as simulações históricas e/ou previsões, podem ser realizadas. Essa pesquisa se ateve a simulações históricas, recomendando-se para pesquisas subsequentes, testar o modelo para previsões a partir de saídas de modelos como da família NMME (Kirtman et al., 2014) e ECMWF (Wang et al., 2019). A Figura 4 ilustra de forma esquemática as etapas necessárias para as simulações da produção (preditando Y) em função dos campos de precipitação acumulada semestrais (preditor X).

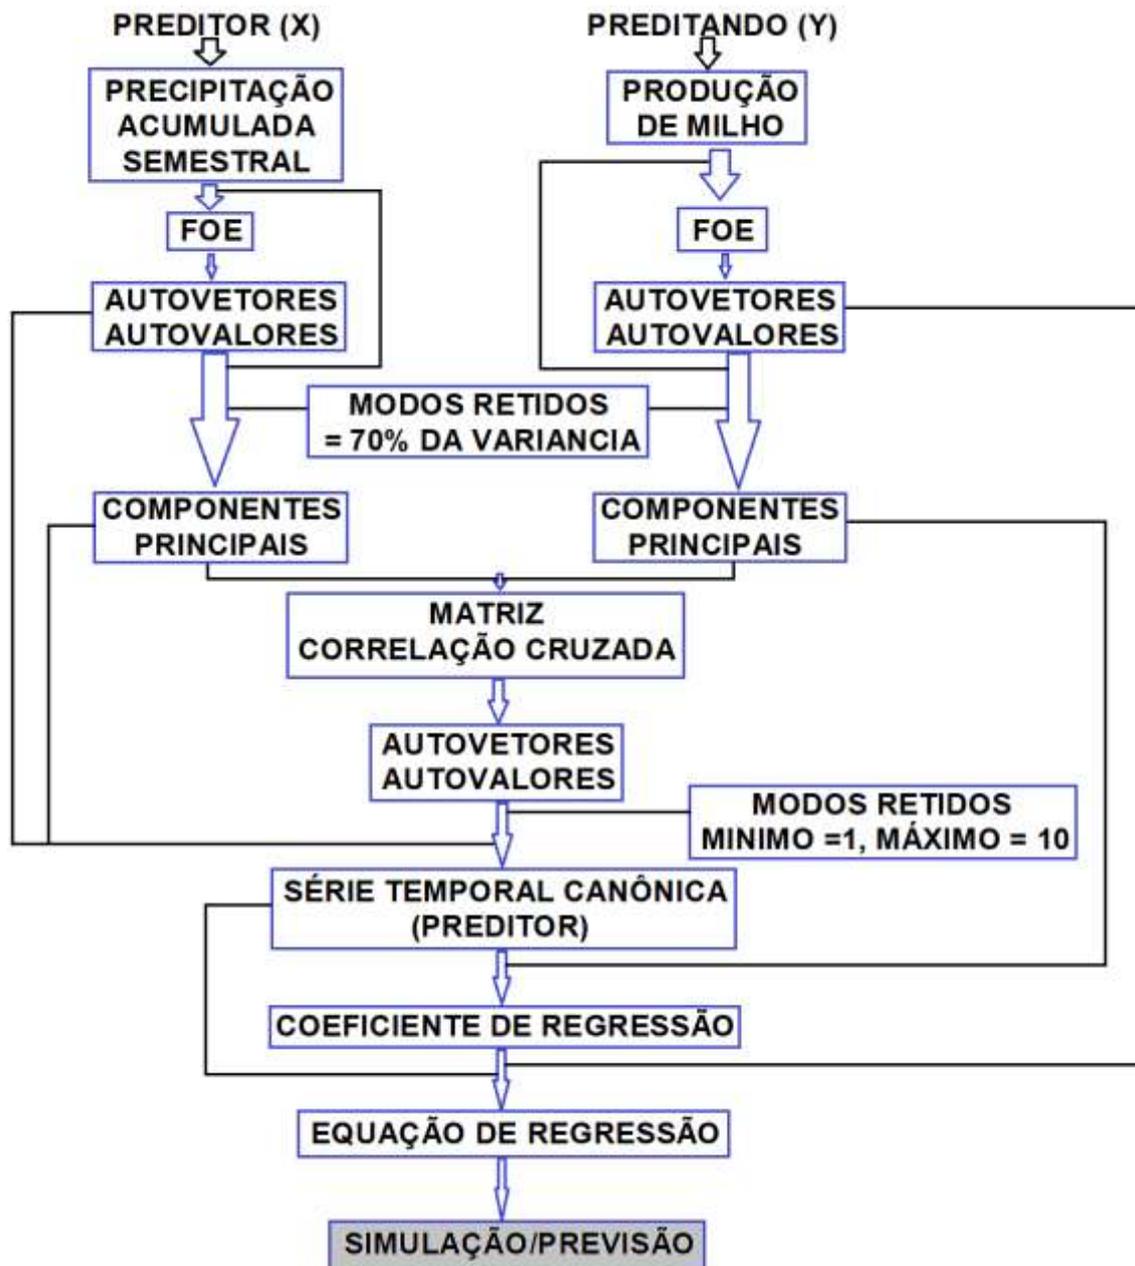


Figura 4. Esquema ilustrativo das etapas utilizadas para as simulações da produção de milho nas mesorregiões do NEB a partir da precipitação acumulada semestral, utilizando (Autor, 2011)

4. RESULTADOS E DISCUSSÕES

4.1 Resultados obtidos pelo modelo de ACC

A partir da verificação do semestre mais chuvoso de cada mesorregião, mostrado na Figura 3, o modelo de ACC foi projetado para operar com de 1 até 10 modos de variabilidade, seguindo o fluxograma apresentado na Figura 4. A variável explicativa, ou preditora (X), foi a precipitação acumulada levando-se em consideração o semestre mais chuvoso de cada mesorregião e no qual, segundo o calendário agrícola da CONAB (2019), efetivamente o milho é cultivado. Para cada mesorregião, foi obtida a variável a ser explicada, ou preditando (Y), que foi a média de produção em kg/ha da mesorregião obtidas pelo IBGE. O modelo foi construído para o período de 30 anos entre 1981 e 2010.

A Figura 5 mostra, para o centroide de cada mesorregião do NEB, as cargas espaciais do primeiro modo de variabilidade para preditor X e preditando Y. O primeiro modo é o mais dominante na correlação entre precipitação acumulada e produção, mostrando que cargas canônicas associadas a precipitação acima da média se associam a produção acima da média. A correlação canônica para este par de variáveis foi de 0,92 para o primeiro modo, que explica mais de 50% da variância dos dados de produção, diretamente proporcionais como indica a Figura 6. Segundo da Rocha Júnior et al (2021), modos retidos de variabilidade que explicam mais de 70% da variância dos dados são suficientes para a construção de um modelo estatístico preditivo, uma vez que outros modos podem adicionar apenas ruído ao modelo sem necessariamente melhorar os valores previstos.

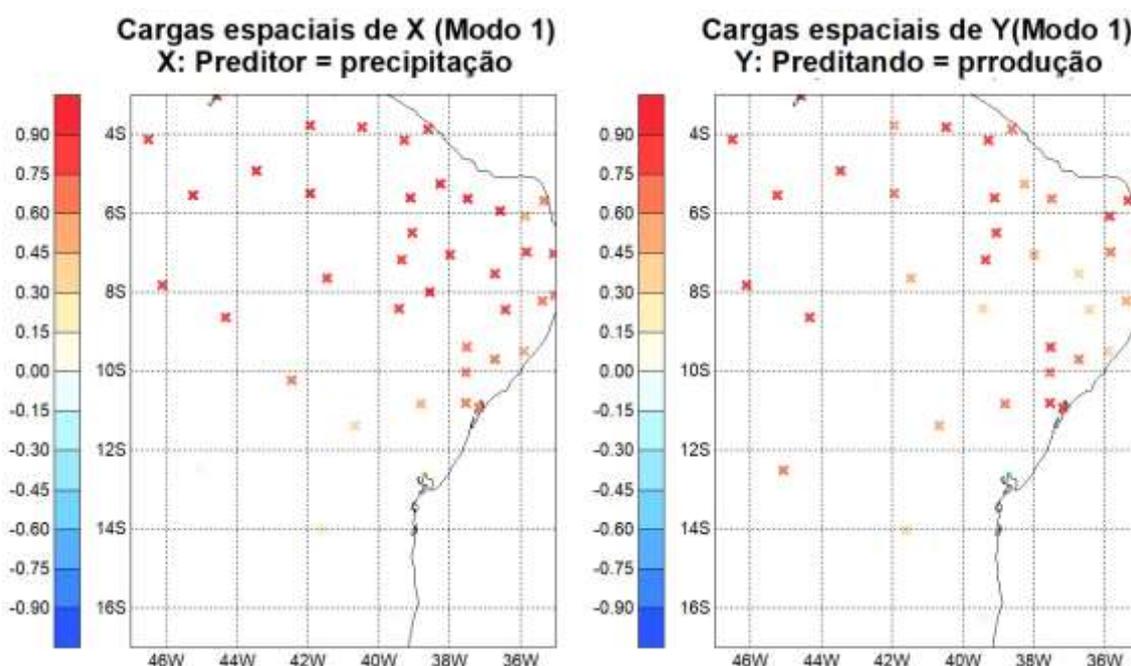


Figura 5. Cargas espaciais de X e Y (modo 1) mostram o padrão mais dominante na correlação de precipitação associada com produção acima do normal. A correlação canônica para este par de variáveis foi superior a 0,92. A partir das pontuações temporais (modo 1), os padrões de precipitação, acima ou abaixo da normal, tendem a coincidir com produção acima do normal e vice-versa. Obtido para o período 1981-2010.

De forma mais simplificada, a associação entre a precipitação do semestre mais chuvoso e a produção observada em cada mesorregião é definida pela combinação linear dos valores de índices associados a cada um dos conjuntos (FOEs), maximizando a correlação entre os dois índices, retendo ao máximo informações contidas nas variáveis originais. A Figura 6 mostra gráficos "scree" para X e Y. O gráfico "scree" em estatística multivariada mostra a linha dos fatores ou componentes principais da análise, e é usado para determinar o número de fatores retidos ou componentes principais mantidas em uma análise, nesse caso, de ACC. Da Figura 6 percebe-se que para X, os cinco primeiros fatores explicam 83% da variância e estes foram escolhidos para a construção do modelo de previsão (57% para o primeiro modo ou componente principal, 8% para o segundo modo, 7% para o terceiro modo, 6% para o quarto modo e 5% para o quinto modo). A correspondência em Y, relativa aos primeiros cinco modos, são consistentes com os modos de X, apenas com percentuais de explicação da variância dos dados de produção um pouco abaixo dos observados nos modos de X (precipitação acumulada).

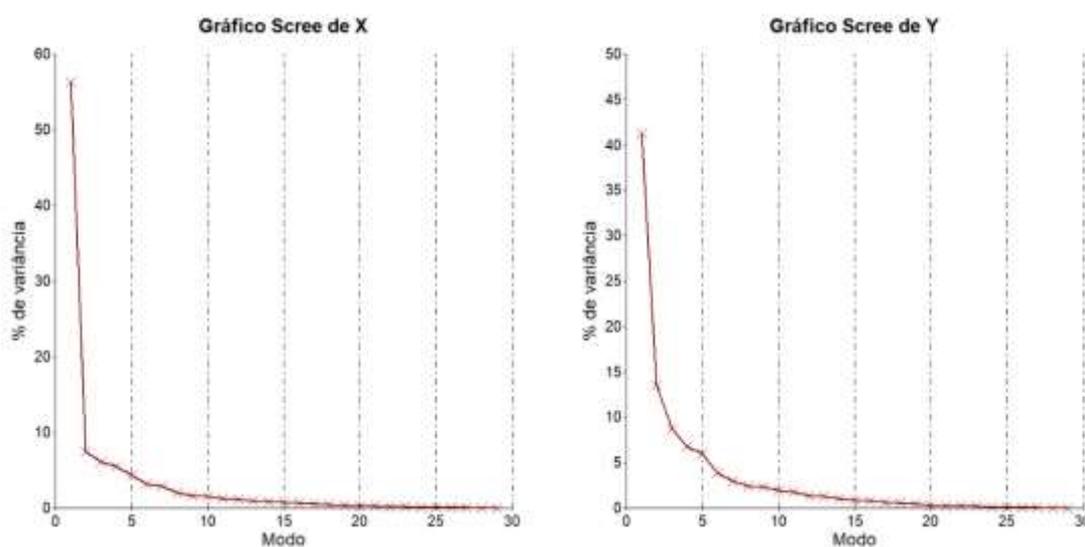


Figura 6. Scree plot do número de modos retidos na análise de componentes principais.

A Figura 7a mostra a comparação entre as correlações (r) obtidas de forma direta entre a precipitação média do semestre mais chuvoso de cada mesorregião e a produção observada de milho em kg/ha. A Figura 7b, à direita, mostra os valores de r após o processamento com o modelo de ACC, ou seja, entre valores previstos e observados da produção. Os resultados evidenciam que há, como já era de se esperar, uma correlação inicial entre a chuva acumulada na estação de cultivo (semestre mais chuvoso) e a produção, no entanto, essa relação não é suficiente para prever com confiabilidade os valores da produção, principalmente em séries que possuem tendência. Já o modelo construído a partir da combinação linear de preditores (a chuva acumulada em cada mesorregião) para previsão das produções foi eficiente em elevar todos os valores de r obtidos da simples comparação entre chuva acumulada e produção. Ainda, observou-se que, em média, os valores de r elevaram-se em aproximadamente 0,2 com os resultados do modelo calibrado. Das 42 mesorregiões entre todos os estados do NEB, apenas três tiveram correlações maiores a partir da comparação direta da produção com a chuva acumulada e inferior com a produção simulada pelo modelo: a mesorregião central potiguar, a mesorregião da Borborema na Paraíba e a mesorregião do sertão pernambucano. Estes valores são melhor observados na Tabela 2.

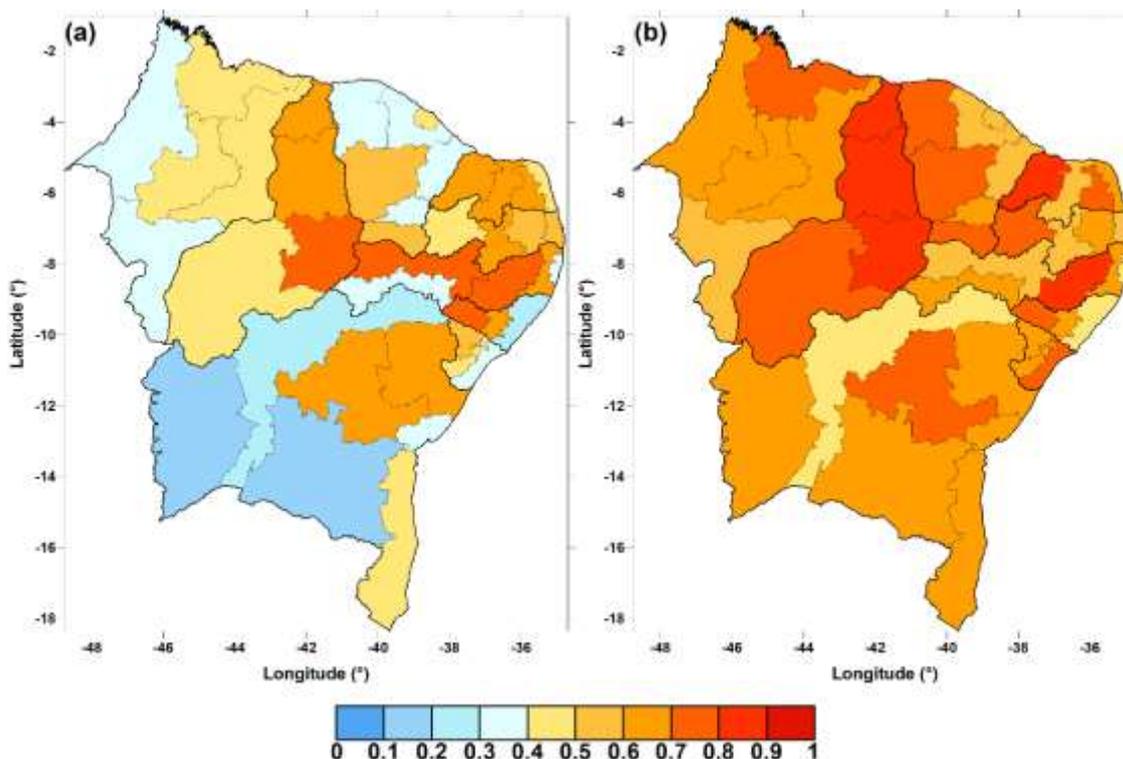


Figura 7. (a) Correlações entre a chuva acumulada na estação de cultivo de cada mesorregião e a produção observada, e (b) correlação entre a produtividade prevista com modelo de ACC e observada. Para o tamanho da amostra, 30 anos, todas as correlações acima de 0,4 são estatisticamente significativas de acordo com o teste *t-student*.

Tabela 3. Para cada mesorregião, valores de correlações (*r*) obtidas da comparação direta chuva acumulada x produção observada, e a partir da produção simulada pelo modelo de ACC e observada. Valores em negrito destacam a maior *r* obtida.

Mesorregião	<i>r</i> - chuva acumulada x produção	<i>r</i> - modelo x produção
Norte Maranhense	0,45	0,74
Oeste Maranhense	0,38	0,65
Central Maranhense	0,47	0,66
Leste Maranhense	0,44	0,66
Sul Maranhense	0,37	0,56
Norte Piauiense	0,62	0,81
Centro Norte Piauiense	0,66	0,82
Sudeste Piauiense	0,71	0,83
Sudoeste Piauiense	0,45	0,70
Noroeste Cearense	0,33	0,78
Norte Cearense	0,31	0,51
Metropolitana de Fortaleza	0,44	0,59
Sertões Cearenses	0,50	0,70
Jaguaribe	0,37	0,53
Centro-Sul Cearense	0,35	0,66
Sul Cearense	0,50	0,73
Oeste Potiguar	0,69	0,80
Central Potiguar	0,64	0,52

Agreste Potiguar	0,63	0,74
Leste Potiguar	0,42	0,62
Sertão Paraibano	0,43	0,71
Borborema	0,60	0,54
Agreste Paraibano	0,63	0,65
Mata Paraibana	0,50	0,56
Sertão Pernambucano	0,76	0,53
São-Francisco Pernambucano	0,39	0,65
Agreste pernambucano	0,75	0,81
Mata Pernambucana	0,64	0,69
Metropolitana do Recife	0,35	0,48
Sertão Alagoano	0,77	0,79
Agreste Alagoano	0,62	0,63
Leste Alagoano	0,20	0,42
Sertão Sergipano	0,53	0,63
Agreste Sergipano	0,43	0,67
Leste Sergipano	0,34	0,71
Extremo Oeste Baiano	0,17	0,68
Vale São Franciscano-BA	0,28	0,43
Centro Sul Baiano	0,16	0,67
Centro Norte Baiano	0,65	0,72
Nordeste Baiano	0,62	0,67
Metropolitana de Salvador	0,36	0,68
Sul Baiano	0,42	0,69

4.2 Resultados por Estado - Maranhão

O estado do Maranhão possui produção de milho em todas as mesorregiões. No período de análise dessa pesquisa, 1981-2010, a média produzida em cada mesorregião foi de 523 kg/ha no norte maranhense, 746 kg/ha no oeste maranhense, 670 kg/ha no centro maranhense, 474 kg/ha no leste maranhense e 1710 kg/ha no sul maranhense. Os gráficos da Figuras 8 mostram a comparação entre a produção observada e simulada pelo modelo em cada mesorregião. Percebe-se boa concordância entre a simulação e observação, principalmente no norte maranhense (Figura 8a), com o modelo acompanhando o aumento da produção observada a partir de 1995, embora com o modelo subestimando as observações a partir de 2000. Essa subestimativa é verificada também no oeste maranhense (Figura 8b), que apresentou tendência de aumento na produção a partir de 2000, no centro maranhense a tendência de aumento inicia-se em 1998 e o modelo subestima a partir de 2003 (Figura 8c), situação similar é verificada no leste maranhense (Figura 8d), e por fim, tal característica de aumento na produção é mais acentuada no sul maranhense (Figura 8e), como consequência do avanço da fronteira agrícola denominada MATOPIBA, que tem no sul desse Estado uma de suas áreas mais produtivas (Salvador e Brito, 2018; Reis et al, 2020). É importante frisar que, em cada mesorregião, principalmente no sul maranhense, antes do aumento na produção o modelo apresenta viés positivo, de superestimar a produção observada.

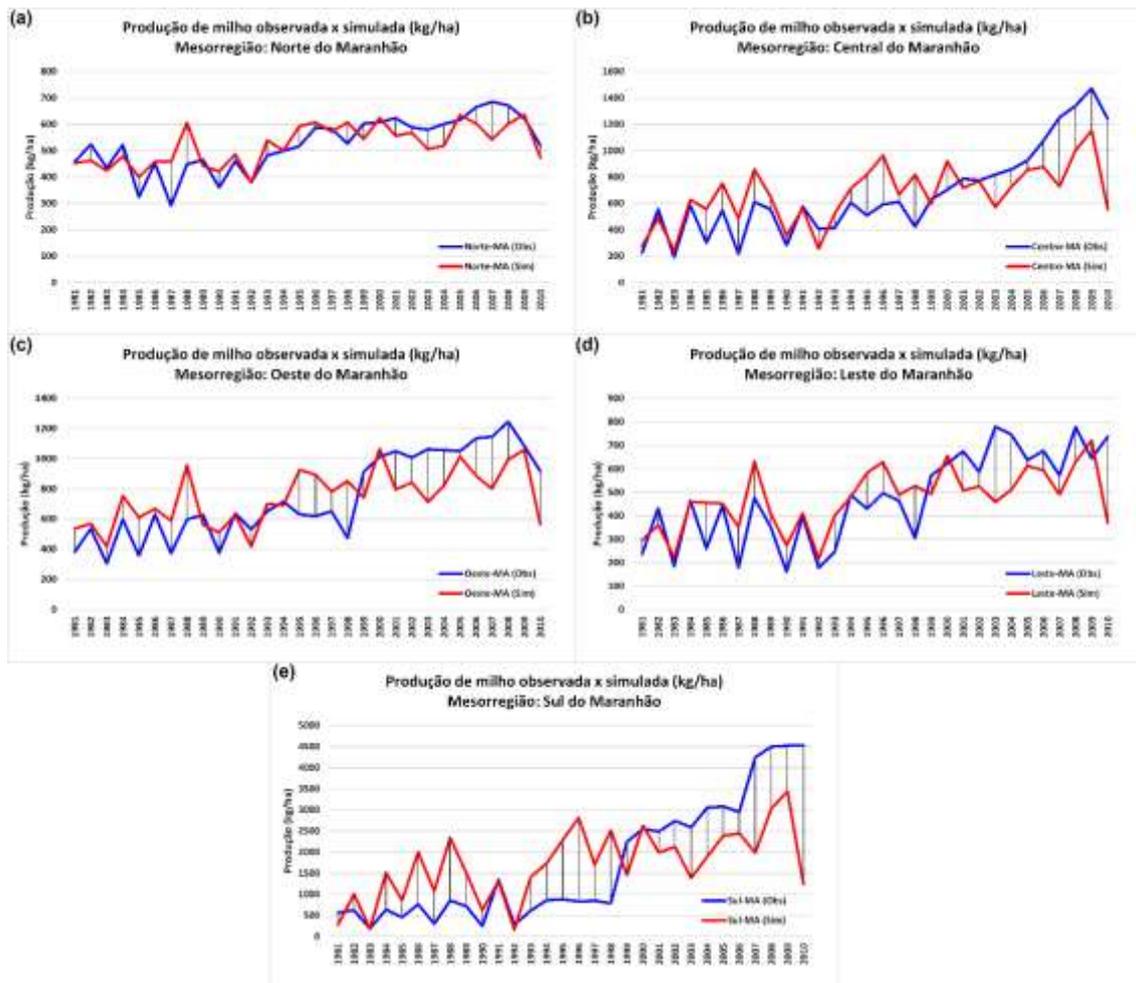


Figura 8. Produção observada (linha azul) e simulada com o modelo de ACC (linha vermelha), para o período 1981-2010, para as mesorregiões do Maranhão: (a) norte maranhense, (b) centro maranhense, (c) oeste maranhense, (d) leste maranhense e (e) sul maranhense.

4.3 Resultados por Estado - Piauí

Os resultados das simulações do modelo para o Piauí mostraram ótima adequação com as observações. Os valores das correlações obtidas foram elevados, 0,81 para o norte piauiense, 0,82 para o centro-norte piauiense, 0,83 para o sudeste piauiense e 0,70 para o sudoeste piauiense possuindo grande significância. A média de produção no período é similar entre as mesorregiões norte, centro-norte e sudeste, da ordem de 480 kg/ha. No sudoeste é de cerca de 825 kg/ha, assim como para o sul do Maranhão, em consequência da expansão agrícola MATOPIBA (Reis et al, 2020), que avançou nessa mesorregião do Piauí, e embora o forte da produção seja a soja (Assad et al, 2007; Pereira et al, 2018), o milho também é plantado em maior escala que nas demais mesorregiões do Estado. As Figuras 13 a 16 mostram que o modelo foi hábil em simular e capturar a maior parte da variação da produção em todas as mesorregiões. Esses resultados evidenciam que no Piauí, a resposta entre variável independente (chuva acumulada) e a variável dependente (produção) é mais direta que em outras mesorregiões de outros Estados. O regime de chuvas está associado ao deslocamento da ZCIT para as mesorregiões (Utida et al, 2019), e em especial para a mesorregião sudoeste, a eventos de precipitação que ocorrem de

outubro a março (). Variações interanuais no deslocamento da ZCIT são decisivos para a qualidade do período chuvoso no norte do NEB (Marengo et al, 2018), sendo o principal fator de sucesso ou fracasso das safras.

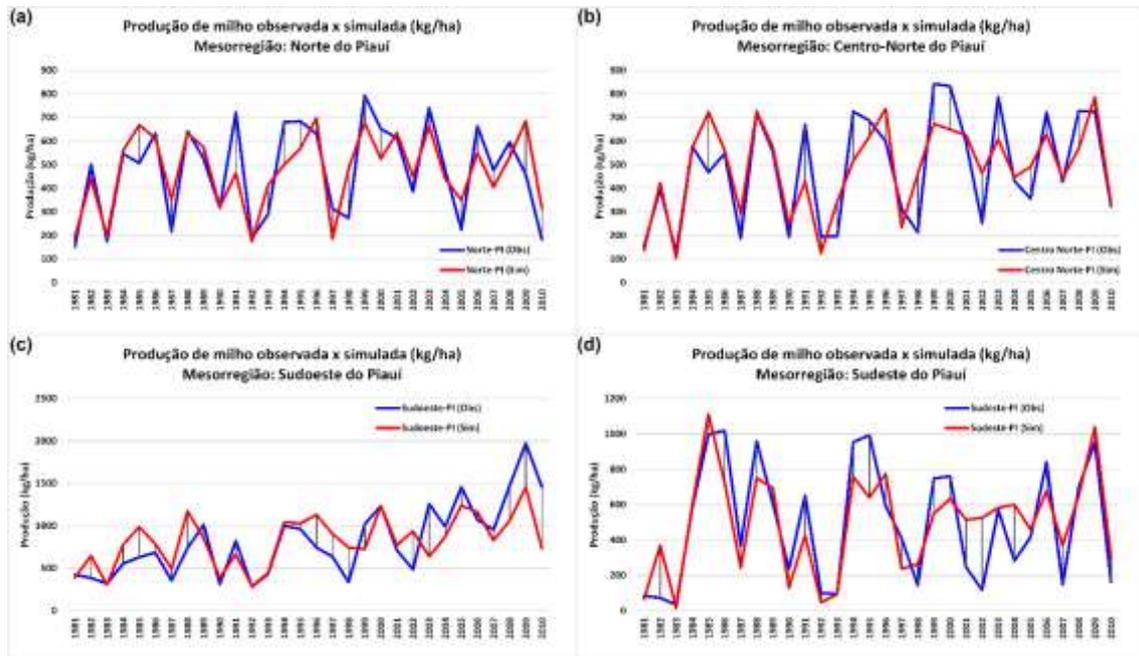


Figura 9. Mesmo da Figura 8, mas para as mesorregiões do Piauí: (a) norte piauiense, (b) centro-norte piauiense, (c) sudoeste piauiense e (d) sudeste piauiense.

4.4 Resultados por Estado - Ceará

O Ceará possui sete mesorregiões (Figura 10), devido ao desmembramento dos municípios limítrofes a capital, que constituíram a mesorregião metropolitana de Fortaleza. Em todo o Estado, o período mais chuvoso é o semestre JFMAMJ, influenciado por sistemas como VCANs cujo ápice de atuação se dá entre janeiro e fevereiro (Costa et al, 2014), ZCIT entre fevereiro e abril (Carvalho e Oyama, 2013), resquícios de DOLs em maio e junho (Gomes et al, 2019), além da interação entre fenômenos de maior escala, como sistemas frontais que induzem formação de complexos convectivos de mesoescala (Veber et al, 2020; Lyra et al, 2020). No entanto, como em todo setor norte do NEB, há grande variabilidade interanual e má distribuição espaço-temporal das chuvas na estação de cultivo, refletindo em anos com maior e menor produção.

Esse padrão que alterna anos (períodos) mais/menos produtivos foi bem captado pelas simulações do modelo em todas as mesorregiões (Figura 10). Entre as mesorregiões, o melhor desempenho baseado nas correlações (r) foi verificado no sul cearense (Figura 10g), seguido do sertão cearense (Figura 10d), centro-sul cearense (Figura 10e), metropolitana de Fortaleza (Figura 10b), Jaguaribe (Figura 10f) e norte do Ceará (Figura 10a).

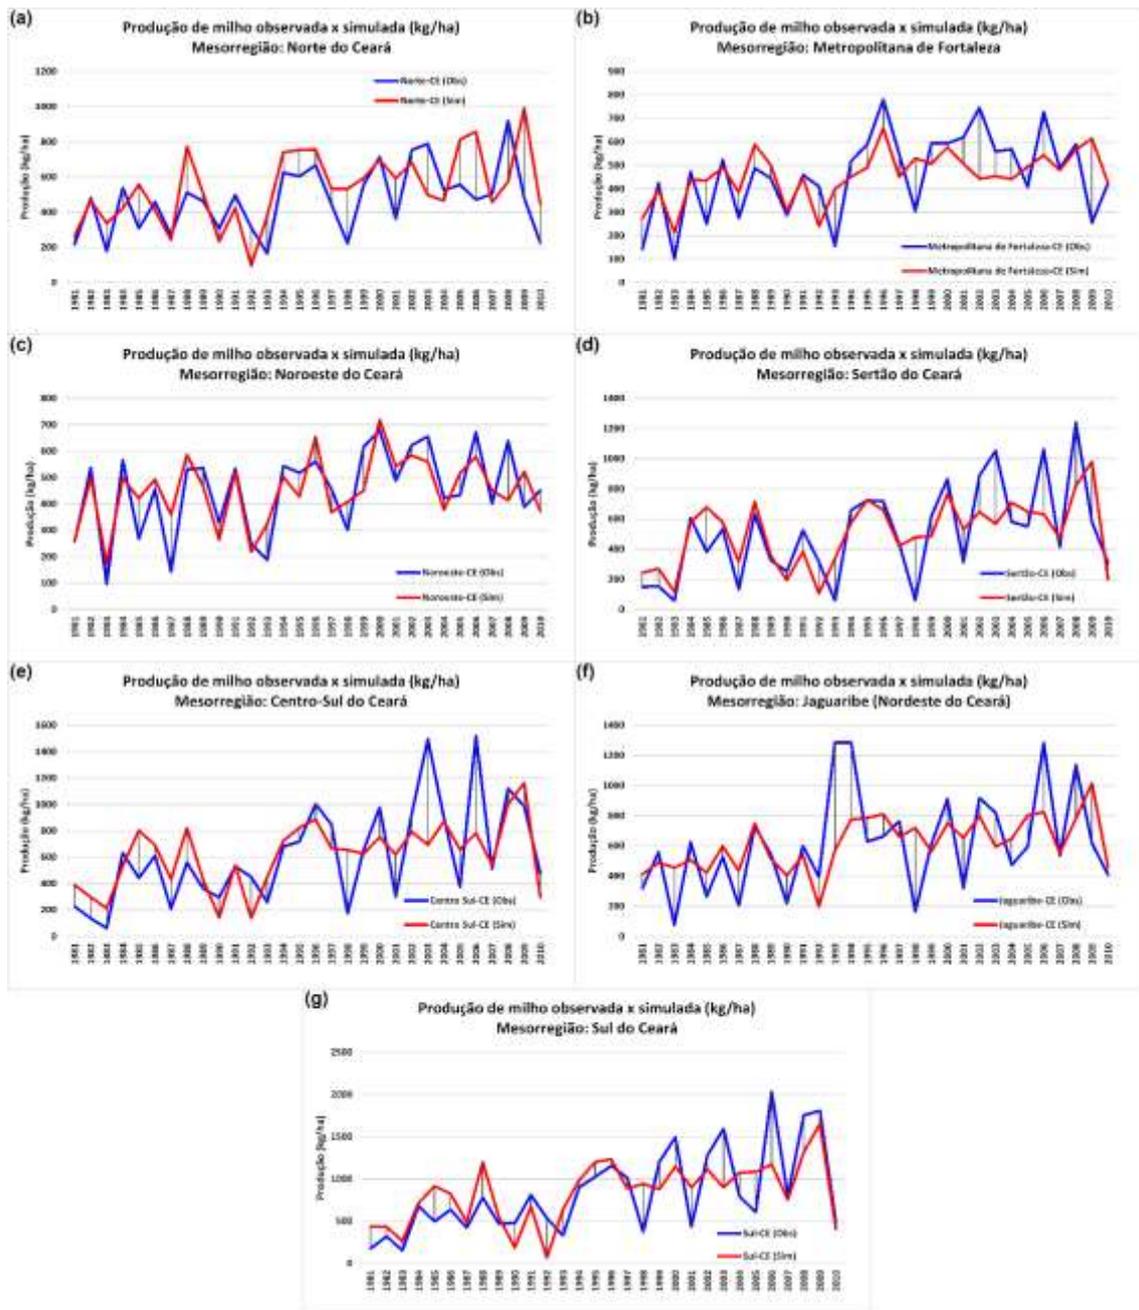


Figura 10. Mesmo da Figura 8, mas para as mesorregiões do Ceará: (a) norte (b) metropolitana de Fortaleza, (c) noroeste, (d) sertão, (e) centro-sul, (f) Jaguaribe e (g) sul cearense.

4.5 Resultados por Estado – Rio Grande do Norte

No Rio Grande do Norte, o melhor desempenho das simulações foi observada nas mesorregiões oeste e agreste, com correlações de 0,80 e 0,74 com as produções observadas, respectivamente (Figuras 11a e 11c) possuindo grande significância, acompanhando a tendência de aumento da produção a partir de meados da década de 1990. A mesorregião central (Figura 11b) apresentou a menor correlação entre simulações e observações, influenciada por dois picos positivos nas observações de 1990 e 1993 não captadas pelo modelo de previsão. O valor observado estimado pelo IBGE para 1993,

especialmente, é suspeito devido à todas as outras mesorregiões apresentarem valores baixos de produção nesse ano, como pode-se perceber de forma mais acentuada no leste potiguar (Figura 11d). O ano de 1993 foi influenciado pela continuidade de uma fase quente do ENOS (El Niño), classificado como de forte intensidade no biênio 1991-1992 e fraco no biênio 1992-1993, ou seja, uma sequência de três anos sob influência de um El Niño estendido, que em média reduz as chuvas especialmente nos estados do setor norte do NEB (Gonzalez et al, 2013).

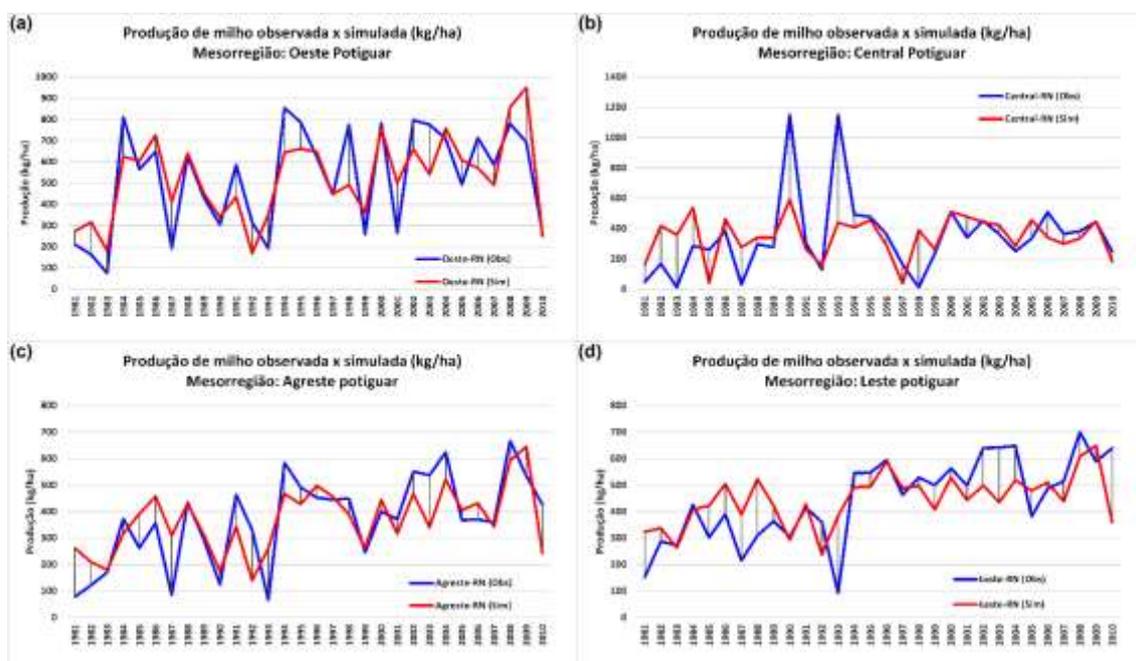


Figura 11. Mesmo da Figura 8, mas para as mesorregiões do Rio Grande do Norte: (a) oeste, (b) central, (c) agreste e (d) leste potiguar.

4.6 Resultados por Estado – Paraíba

Assim como observado para o Rio Grande do Norte, o setor oeste da Paraíba em sua mesorregião sertão, foi a que apresentou as maiores correlações entre a produção simulada e observada possuindo grande significância ($r = 0,71$), seguida das mesorregiões agreste, mata paraibana e Borborema, que compreende as microrregiões do cariri e curimataú paraibanos, considerada uma das áreas de menores índices pluviométricos do Brasil (Alves et al, 2015). Nota-se a habilidade do modelo em captar o comportamento observado, embora com dificuldade para simular alguns picos positivos/negativos específicos observados no período 1981-2010. Entre 1994 e 1997, o modelo captou e simulou bem esse período com observações acima da média, de forma mais clara nas mesorregiões sertão (Figura 12a), Borborema (Figura 12b) e agreste (Figura 12c). A mesorregião da mata paraibana (Figura 12d) apresentou um pico na produção observada em 2003 que não foi captada pelo modelo. Diferente do pico observado em 1993 na mesorregião central do Rio Grande do Norte, este não é um valor suspeito, pois também foi um ano de alto valor observado na mesorregião agreste.

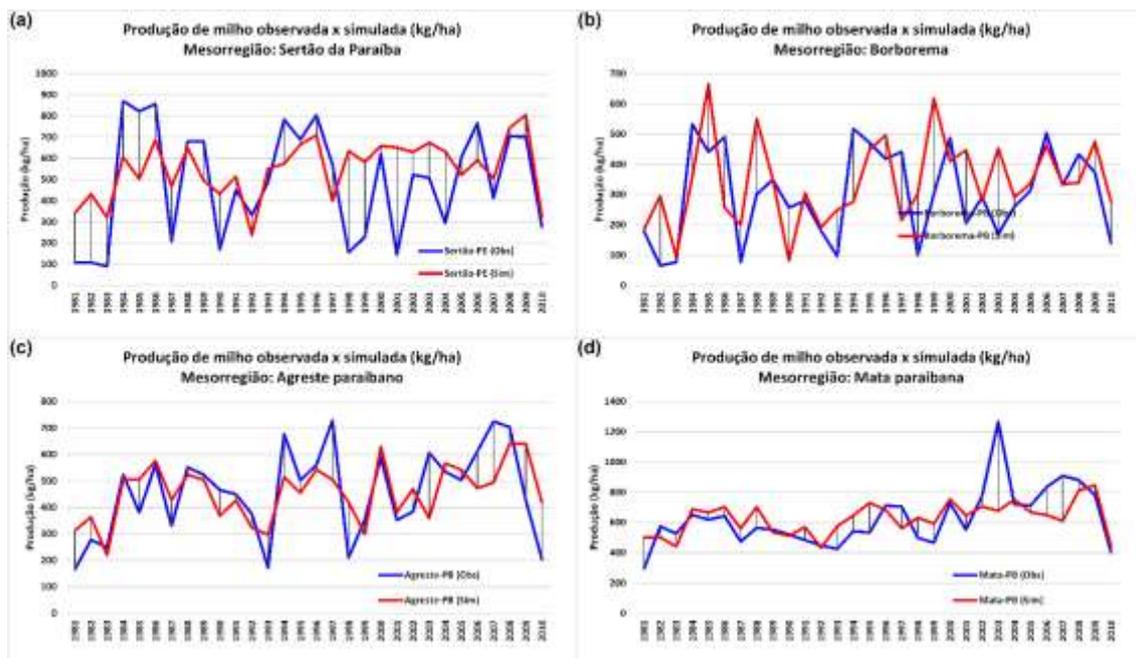


Figura 12. Mesmo da Figura 8, mas para as mesorregiões da Paraíba: (a) sertão, (b) Borborema, (c) agreste e (d) mata paraibana.

4.7 Resultados por Estado – Pernambuco

Em termos de valores médios em quilogramas por hectare, a produção de milho é muito homogênea em quatro das cinco mesorregiões pernambucanas, com valores médios de 480 kg/ha no sertão pernambucano (Figura 13a), 428 kg/ha no vale do rio São Francisco (Figura 13b), 437 kg/ha no agreste (Figura 13c) e 424 kg/ha na zona da mata (Figura 13d), destoando dessa homogeneidade apenas a mesorregião metropolitana de Recife com produção média de 725 kg/ha.

O modelo simulou bem as observações, sem viés preferencial, com a maior correlação versus as observações obtida para o agreste ($r = 0,81$), e a menor na mesorregião metropolitana de Recife ($r = 0,48$). Os baixos valores de produtividade do milho na maior parte das mesorregiões pernambucanas é reflexo da prática de sequeiro e por este ser um dos Estados do Nordeste com a maior taxa de retorno de secas moderadas a severas (Pereira et al, 2017; da Rocha Júnior et al, 2020).

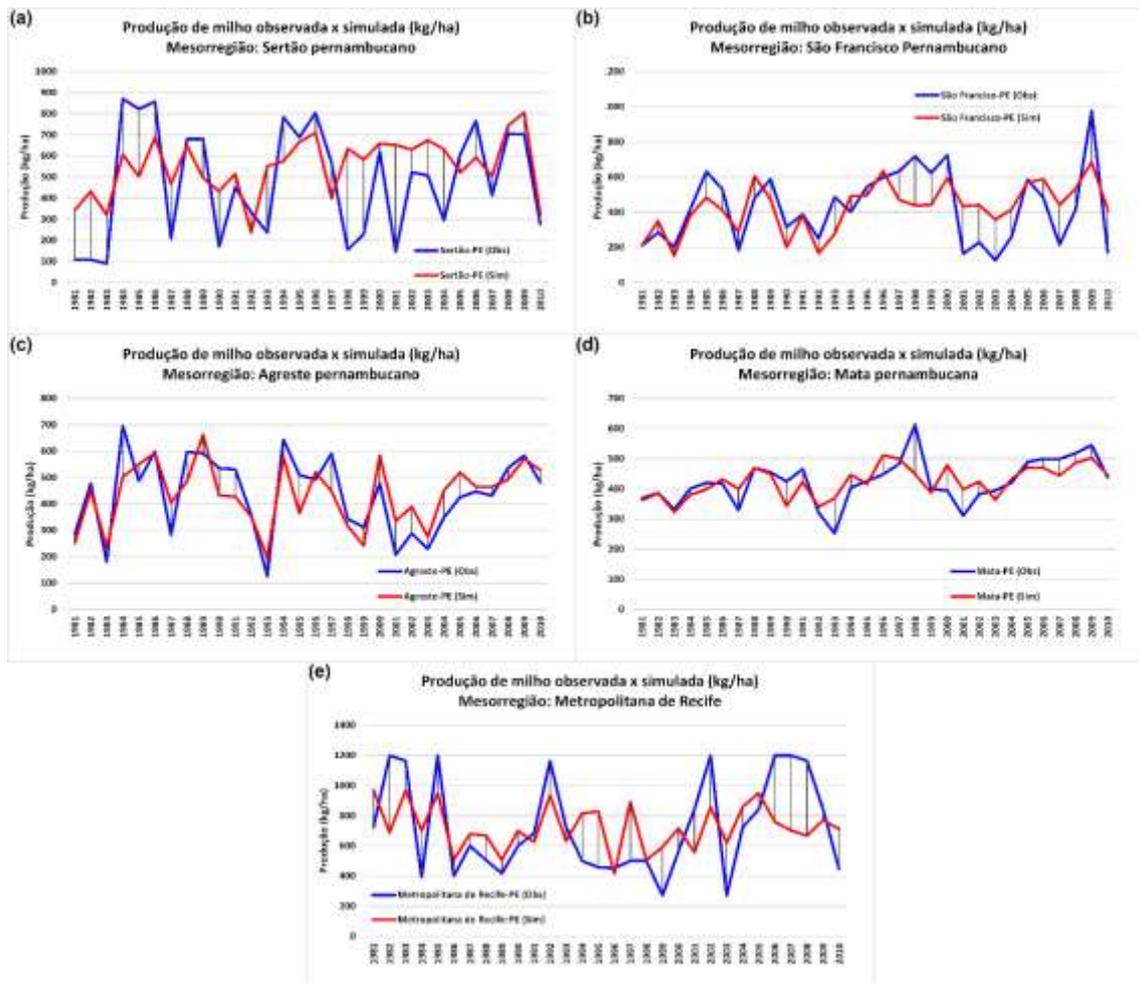


Figura 13. Mesmo da Figura 8, mas para as mesorregiões de Pernambuco: (a) sertão, (b) vale do São Francisco, (c) agreste, (d) mata e (e) metropolitana de Recife.

4.8 Resultados por Estado – Alagoas e Sergipe

Alagoas e Sergipe são dois Estados do leste nordestino com semelhanças entre si, ambos possuem três mesorregiões: sertão, agreste e leste, possuem basicamente o mesmo regime climático, com período mais chuvoso, ou estação de cultivo, de abril a setembro, cuja maior influência sobre o regime de precipitação é devido ao transporte de umidade do Oceano Atlântico pelos ventos alísios de leste/sudeste que, por muitas vezes estão associados a DOLs (Gomes et al, 2015; 2019). Silva et al (2018), avaliaram eventos extremos de precipitação no leste do NEB e investigaram suas causas climáticas, concluindo que fenômenos de diferentes naturezas em diferentes escalas temporais são responsáveis pela dinâmica das chuvas nessa região, como ENOS, dipolo do Atlântico, oscilação decadal do Pacífico e ciclo de manchas solares.

No entanto, a produção de grãos, nesse caso o milho, apresenta diferenças entre as mesorregiões desses Estados no período analisado. Alagoas tem uma média de produção de 359 kg/ha na mesorregião sertão (Figura 14a), 567 kg/ha na mesorregião agreste (Figura 14b), e 533 kg/ha na mesorregião leste (Figura 14c), valores inferiores aos observados para Sergipe, com uma produção média de 1239 kg/ha no sertão (Figura 15a), 880 kg/ha superior ao produzido no sertão alagoano, 997 kg/ha no agreste (Figura

15b), 430 kg/ha superior ao produzido no agreste alagoano, e 773 kg/ha no leste (Figura 15c), 240 kg/ha superior ao produzido no leste alagoano. As diferenças nos setores leste e agreste podem ser explicadas pela maior predominância do cultivo de cana de açúcar nessas mesorregiões de Alagoas do que em Sergipe (EMBRAPA 2015), no entanto, a grande diferença observada para as produções no sertão de cada Estado precisam ser melhor investigadas. Silva et al (2019), citam o incentivo ao crédito agrícola e tipo de solo como fatores determinantes para a expansão do cultivo do milho em Sergipe, e políticas relativas ao efeito do Zoneamento Agrícola de Risco Climático (ZARC), uma política agrícola executada pela Embrapa que exerceu um efeito superior na produtividade do milho no Território Rural do Sertão Ocidental (TRSO) sergipano em comparação aos municípios vizinhos de outras mesorregiões.

Vale salientar que todo agreste e leste desses Estados, e parte do Nordeste baiano, vem experimentando um forte crescimento relativo a expansão agrícola, em uma nova fronteira agrícola denominada SEALBA (Silva et al, 2020), com alto potencial para agricultura mecanizada. Tais efeitos da produção de grãos no SEALBA, como o milho, se deu após o ano de 2010, logo, tal efeito ainda não foi detectado no período de análise dessa pesquisa: 1981-2010.

Os modelos simularam melhor a variabilidade da produção de milho no sertão alagoano ($r = 0,79$) e no leste sergipano ($r = 0,71$), nas demais mesorregiões, foi eficiente em acompanhar as tendências e alguns picos da produção observada.

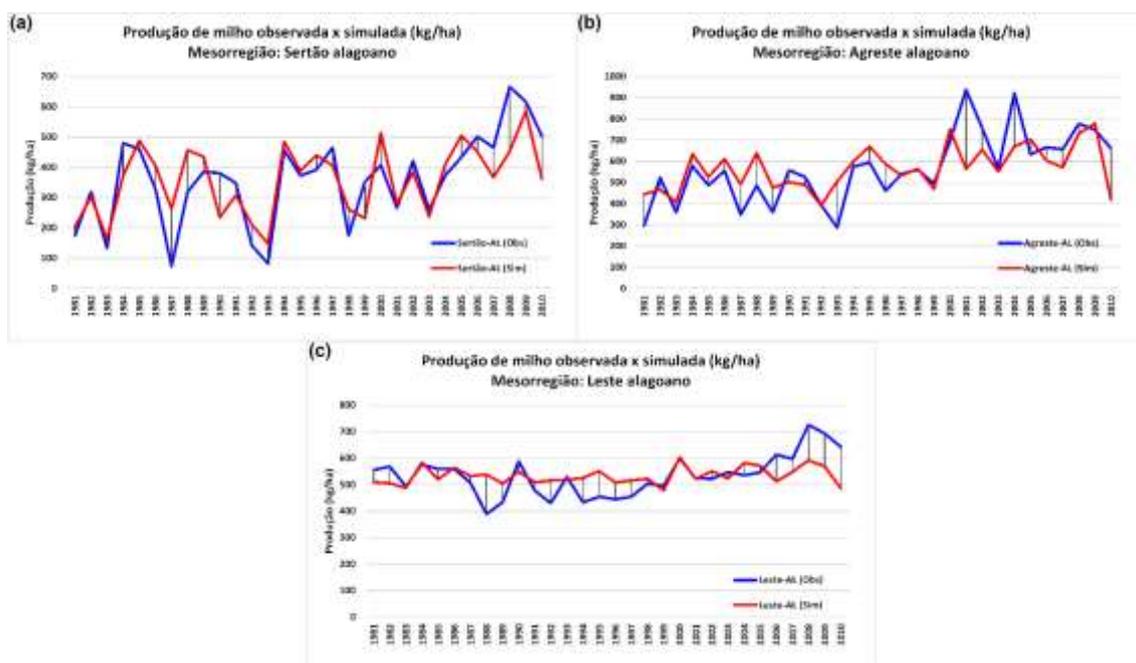


Figura 14. Mesmo da Figura 8, mas para as mesorregiões de Alagoas: (a) sertão, (b) agreste e (c) leste alagoano.

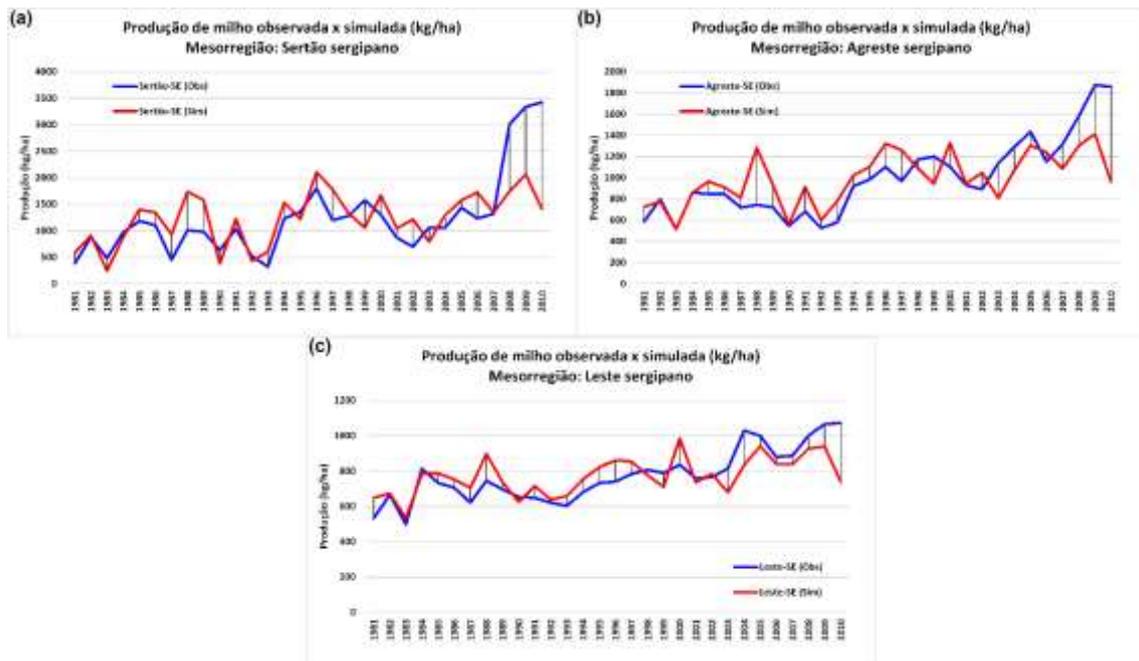


Figura 15. Mesmo da Figura 8, mas para as mesorregiões de Sergipe: (a) sertão, (b) agreste e (c) leste sergipano.

4.9 Resultados por Estado – Bahia

Maior estado do NEB, a Bahia possui sete mesorregiões, o extremo oeste baiano, o vale são-franciscano baiano, o nordeste, centro-norte, metropolitana de Salvador, centro-sul e sul baiano. A produção média de 1981 a 2010 variou de 521 kg/ha no centro-norte baiano a 2158 kg/ha no extremo oeste baiano, em torno de 650 kg/ha no vale do São Francisco, centro-sul e nordeste da Bahia, e em torno de 820 kg/ha na região metropolitana de Salvador e no sul baiano. Pela sua extensão e diferentes formas de cultivo, a Bahia é um exemplo clássico de um Estado que possui três classes distintas de produtividade: alta produtividade no extremo oeste, relacionado a área do estado inserido no MATOPIBA, produtividade moderada no sul e região metropolitana de Salvador, e baixa produtividade nas demais mesorregiões. O maior desafio no desenvolvimento de qualquer modelo é conseguir que ele capte picos aleatórios e tendência de uma série temporal. Nesse caso mais específico, o desafio seria o modelo captar a mudança abrupta no patamar de produtividade observada no extremo oeste baiano a partir da década de 1990 com o avanço da fronteira agrícola nesse setor do Estado (Santos, 2018). A Figura 16a mostra a simulação versus a observação no extremo oeste baiano, e torna-se evidente que o modelo captou o novo patamar médio de produção, que saltou de uma média aproximada de 1000 kg/ha entre 1981 e 1990, para uma média de aproximadamente 2700 kg/ha entre 1991 e 2010, com tendência de novo aumento no final da série, com uma correlação de 0,68 entre valores simulados e observados. Nas demais mesorregiões, como observado nas análises para os demais estados, percebe-se que o modelo possui destreza e acompanha o comportamento observado. Nas demais mesorregiões, as correlações entre simulações e observações foi de 0,43 no vale do São Francisco, a mais baixa entre as mesorregiões (Figura 16b), 0,67 no nordeste baiano (Figura 16c), 0,72 no centro-norte baiano (Figura 16d), 0,69 na região metropolitana de Salvador (Figura 16e), 0,67 no centro-sul baiano (Figura 16f), e 0,69 no sul baiano (Figura 16g).

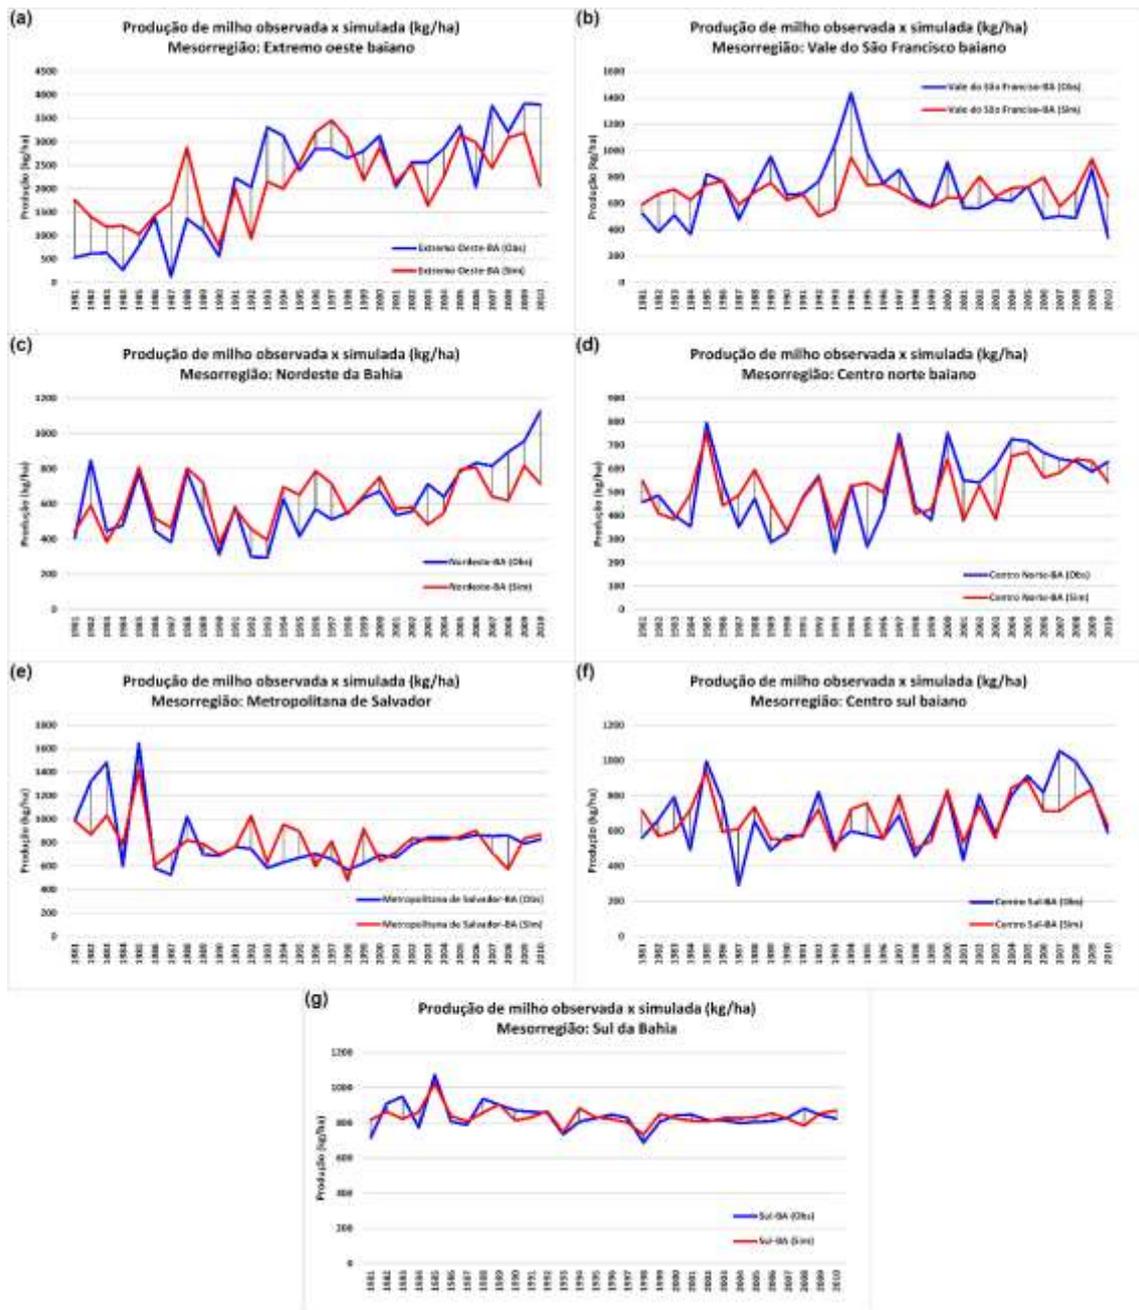


Figura 16. Mesmo da Figura 8, mas para as mesorregiões da Bahia: (a) extremo oeste, (b) vale do São Francisco, (c) nordeste, (d) centro-norte, (e) metropolitana de Salvador, (f) centro-sul e (g) sul da Bahia.

4.10 Interação Oceano-Atmosfera x Produção

As análises da performance do modelo construído baseado em ACC mostram que, em todas as mesorregiões do Nordeste, a produção observada anual do milho pode ser bem simulada por essa natureza de modelos estatísticos. Observou-se também a grande variabilidade interanual da produção, que foi bem captada pelo modelo. No entanto, o clima do NEB é complexo, e a distribuição das chuvas é a resposta de vários fenômenos oceânicos e atmosféricos conectados entre si. Estudos clássicos já demonstraram a relação entre o El Niño-Oscilação Sul e a variabilidade intrasazonal e interanual da ZCIT (Philander 1990; Trenberth 1997). O dipolo de anomalias da

temperatura da superfície do mar no atlântico norte e sul exercem igualmente forte influência na dinâmica de chuvas do NEB (Moura e Shukla, 1981; Nobre e Shukla, 1996) Como esses fenômenos em suas diferentes fases ocorrem simultaneamente, pode-se ter até nove diferentes combinações ao relacionar as fases do ENOS e do DA: DA negativo + Pacífico negativo (La Niña), DA negativo + Pacífico neutro, DA negativo + Pacífico positivo (El Niño), DA neutro + Pacífico negativo, DA neutro + Pacífico neutro, DA neutro + Pacífico positivo, DA positivo + Pacífico negativo, DA positivo + Pacífico neutro e DA positivo + Pacífico positivo.

Cada ano entre 1981 e 2010 foi classificado a partir dessas combinações, conforme demonstrado na Tabela 3, e em seguida foram obtidos os desvios percentuais da produção média para cada par das combinações em relação a produção média observada de cada mesorregião no período 1981-2010. A classificação das fases do Pacífico foi realizada baseada no índice oceânico de Niño (ONI, de sua sigla em inglês, https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php), descrito em Huang et al (2017), e das fases do DA na diferença entre anomalias da TSM em área do Atlântico norte de 5.5°N a 23.5°N e de 15°W a 57.5°W, com anomalias da TSM em área do Atlântico sul de 0° a 20°S e de 10°E a 20°W (<https://psl.noaa.gov/data/correlation/tna.data>; <https://psl.noaa.gov/data/correlation/tsa.data>) (Enfield et al, 1999; Servain et al, 2003).

Tabela 4. Anos compostos classificados de acordo com as definições dos eventos climáticos observados nos oceanos Pacífico e Atlântico. DIP: dipolo do Atlântico; Pac: Pacífico; Neg: negativo; Neu: neutro; Pos: positivo.

Variáveis climáticas	Anos
DipNeg/PacNeg	1984, 1985, 1986, 1989, 2000, 2008
DipNeg/PacNeu	1991, 1994
DipNeg/PacPos	1988, 1995, 2003, 2009, 2010
DipNeu/PacNeg	1996, 1999
DipNeu/PacNeu	1982, 1990, 1993, 2004
DipNeu/PacPos	1987, 1998, 2002, 2006, 2007
DipPos/PacNeg	1997
DipPos/PacNeu	1980, 1981, 2001, 2005
DipPos/PacPos	1983, 1992

A Figura 17 mostra os desvios percentuais médios da produção para as combinações DipNeg/PacNeg (a), DipNeg/PacNeu (b) e DipNeg/PacPos (c). As mesorregiões no interior semiárido entre os estados do Piauí, Ceará, Rio Grande do Norte, Paraíba e Pernambuco apresentaram em sua maioria ganho de rendimento, com exceção do norte, oeste e sul maranhense, e extremos oeste da Bahia para a combinação Dipolo negativo e Pacífico negativo (Figura 17a), todas as mesorregiões do Maranhão, do centro-leste da Bahia, de Sergipe e agreste e leste alagoanos para a combinação Dipolo negativo e Pacífico neutro (Figura 17b). A combinação dos anos com Dipolo negativo e Pacífico positivo foi a que apresentou a maior parte das mesorregiões com aumento médio da produção, com destaque para todo o norte do NEB, Alagoas e Sergipe no leste do NEB, e as mesorregiões do oeste baiano, vale do São Francisco, nordeste, metropolitana de

Salvador e sul baiano (Figura 17c), chegando a mais de 60% em relação a média no sertão sergipano.

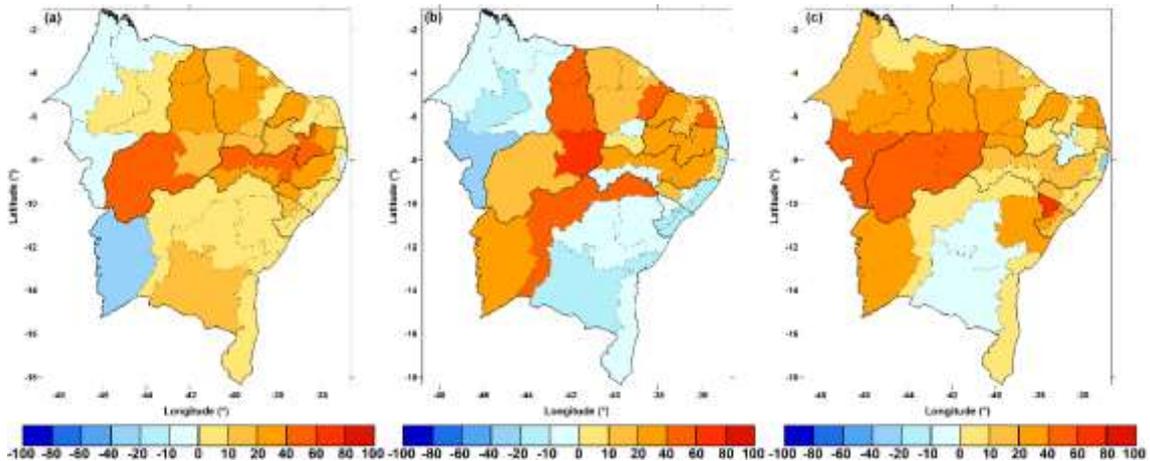


Figura 17. Desvio médio da produção em relação à média do período 1981-2010 de anos classificados sob a influência de Dipolo do Atlântico negativo e (a) Pacífico negativo, (b) Pacífico neutro e (c) Pacífico positivo.

Sob condições neutras do DA, a maior parte das mesorregiões do norte do NEB apresentam desvios positivos de produção em relação à média, ocorrendo o contrário na maior parte das mesorregiões do leste do NEB (Figura 18a). Para a combinação DA neutro e Pacífico neutro, com exceção de poucas mesorregiões que apresentaram um baixo desvio positivo da produção, a maior parte das mesorregiões apresentaram desvios negativos, ou seja, com produção inferior a média, de até -60% no sudeste piauiense (Figura 18b). A combinação DA neutro e Pacífico positivo não apresenta homogeneidade, com mesorregiões alternando desvios positivos e negativos, com os negativos mais concentrados nas mesorregiões do Piauí e Pernambuco, e os positivos no centro-oeste maranhense, centro-sul cearense, e extremo leste do NEB (Figura 18c).

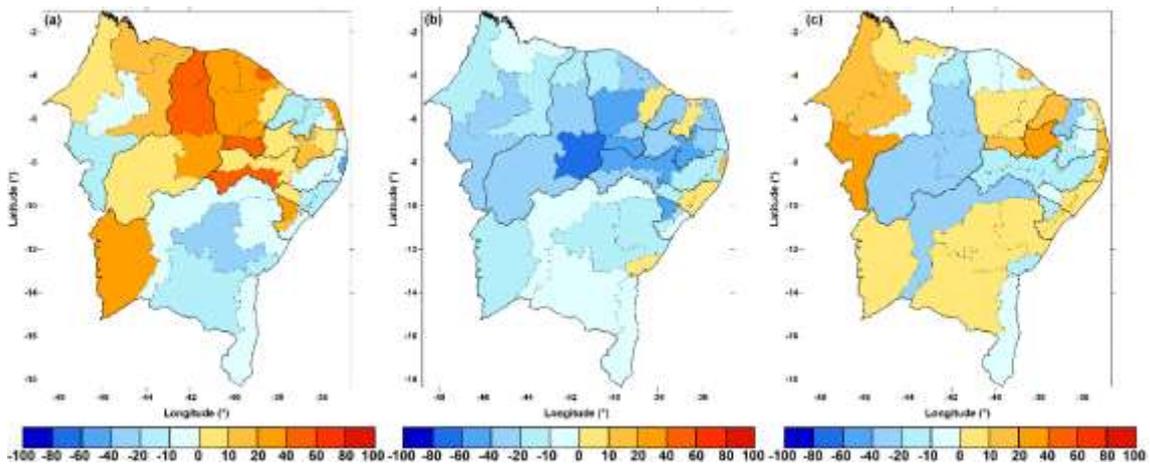


Figura 18. Desvio médio da produção em relação à média do período 1981-2010 de anos classificados sob a influência de Dipolo do Atlântico neutro e (a) Pacífico negativo, (b) Pacífico neutro e (c) Pacífico positivo.

Por fim, tem-se a análise das combinações para DA positivo e as fases do Pacífico. Para DA positivo e Pacífico negativo, a porção oeste do NEB que envolve a maior parte

das mesorregiões do Maranhão, Piauí e algumas do Ceará, Rio Grande do Norte e Paraíba, apresentaram em média redução no percentual de produção, fato também observado em mesorregiões do leste do NEB de Pernambuco a Bahia (Figura 19a). A combinação DA positivo e Pacífico neutro (Figura 19b) já evidenciaram a maior parte do centro-leste do NEB com desvios negativos da produção, com exceção relevante em mesorregiões do Maranhão e no sudoeste piauiense. Já a combinação DA positivo e Pacífico positivo representou a situação mais prejudicial a produção de milho, superando -80% no sul maranhense e sudeste piauiense, a exceção nesse caso se deu apenas para as mesorregiões centro-sul, metropolitana de Salvador e sul da Bahia (Figura 19c).

Tal fato já foi investigado e os resultados para essa última combinação vão ao encontro dos resultados obtidos por Alves et al (2009), ao investigar a influência das diferentes fases do Pacífico e Atlântico na produção de milho e feijão para o Ceará entre 1952 e 2000.

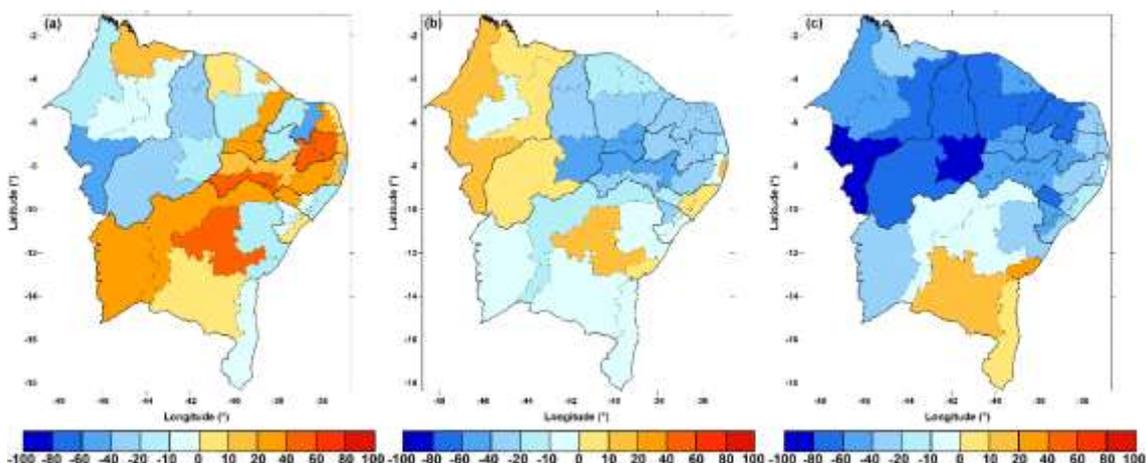


Figura 19. Desvio médio da produção em relação à média do período 1981-2010 de anos classificados sob a influência de Dipolo do Atlântico positivo e (a) Pacífico negativo, (b) Pacífico neutro e (c) Pacífico positivo.

5. CONCLUSÕES

O modelo baseado em ACC, relacionando preditor (chuva acumulada no semestre mais chuvoso, ou “estação de cultivo”) e preditando (produção do milho por mesorregiões do NEB), apresentou, na maior parte das mesorregiões, correlações moderadas a altas, corroborando sua eficácia em captar o comportamento das séries temporais das observações. Foi observado que já existia correlações estatisticamente significantes relacionando de forma simples a chuva acumulada com a produção, mas o modelo de ACC apresentou simulações que foram mais próximas dos valores observados, aumentando a correlação ao utilizar a chuva acumulada como preditora da produção observada.

Existe uma relação estatística bem definida entre a variabilidade climática dos Oceanos tropicais (Pacífico e Atlântico) e a produção do milho, o que deve ocorrer por similaridade com outros cultivos. Para agricultura de sequeiro, como se dá a maior parte da agricultura familiar do NEB, em geral para anos com a combinação de dipolo do Atlântico negativo e Pacífico negativo (La Niña), houve desvios positivos na produção

em relação à média, o que se repetiu mesmo na combinação entre dipolo negativo e Pacífico positivo (El Niño), evidenciando que as condições de TSMs do Atlântico tendem a impactar mais o clima do NEB que as do Pacífico, possivelmente inibindo efeitos negativos (redução das chuvas) associadas a eventos de El Niños fracos e/ou moderados, uma vez que estudos já demonstraram que em casos excepcionais de El Niños muito fortes sua influência sobre a redução de chuvas no NEB se sobrepõem a influenciaram de uma condição de dipolo negativo. Para condições de dipolo do Atlântico neutro, os resultados mais expressivos se deram da combinação com Pacífico negativo, que resultou em desvios positivos da produção no norte do NEB, e um resultado surpreendente veio da combinação de dipolo neutro e Pacífico neutro, com redução (desvios percentuais negativos) da produção na maior parte das mesorregiões nordestinas.

Por fim, analisando as três combinações do Pacífico com a condição do dipolo do Atlântico positivo, o resultado de desvios negativos da produção para dipolo positivo e pacífico positivo (El Niño) foi confirmado, com maior efeito para o norte do NEB, com algumas mesorregiões com perdas relativas superiores a 90% em relação a média observada de produção do período.

6. REFERENCIAS BIBLIOGRAFICAS

ABIMILHO. Associação Brasileira das Indústrias de Milho (2020). **Milho**. Disponível em: <<http://www.abimilho.com.br/milho/cereal>>. Acesso em: 25 Março.

ADAMS, M.W.; GRAFIUS, J.E. **Yield componente compesation alternative interpretations. Crop Sci., Madson**, v. 11, p. 33-35, 1971.

ALVALA, R.C.S.; 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**, v. 91, p. 1–15, 2017.

ALVARENGA, R.P.; QUEIROZ, T.R.; NADAE, J. Risco tóxico e potencial perigo ambiental no ciclo de vida da produção de milho. **Espacios**, v.38 (1), , p.12, 2017.

ALVES, J.M.; REPELLI, C.A. A variabilidade pluviométrica no setor norte do nordeste e os eventos El Nino-Oscilação Sul (ENOS). **Revista Brasileira de Meteorologia**, v. 7, p. 583–592, 1992.

ALVES, J.M.B. Recentes variações climáticas no Nordeste do Brasil com ênfase a precipitação: Relações com o ENOS, dipolo de temperatura da superfície do mar no atlântico tropical e a oscilação decadal do pacífico. **Revista de Geografia (UFPE)** V. 29, No. 3, 2012.

ALVES, B.M.; CARGNELUTTI FILHO, A.; BURIN, C. Multicollinearity in canonical correlation analysis in maize. **Genetics and Molecular Research**, v. 16(1), p. 1–14, 2017.

ARIEL ORTIZ-BOBEA,; TOBY R. AULT,; CARLOS M. CARRILLO,; ROBERT G. CHAMBERS & DAVID B. LOBELL Anthropogenic climate change has slowed global agricultural productivity growth. **Nature Climate Change**, v. 11, p. 306-312, 2021.

ANDRADE, J.A.; ABREU, F.G. Influência da temperatura e do teor de humidade do solo na área foliar e acumulação de matéria seca durante o estabelecimento da ervilha, do milho e do girassol. **Revista de Ciências Agrárias**, v. 30, n. 2, p. 27-37, 2007.

BARNETT, T.P.; PREISENDORFER, R. Origins and levels of monthly and seasonal forecast skill for United States surface air temperatures determined by canonical correlation analysis. **Monthly Weather Review**, v. 115, p. 1825–1850, 1987.

BARNSTON, A.G. Linear statistical short-term climate predictive skill in the Northern Hemisphere. **Journal of Climate**, v. 7, p. 1513–1564, 1994.

BARNSTON, A.G.; SMITH, T.M. Specification and prediction of global surface temperature and precipitation from global SST using CCA. **Journal of Climate**, v. 9, p. 2660-2697, 1996.

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

BARRETO, N.J.C.; MESQUITA, M.S.; MENDES, D.; SPYRIDES, M.H.C.; PEDRA, G.U.; LUCIO, P.S. Maximum covariance analysis to identify intraseasonal oscillations over tropical Brazil. **Climate Dynamics**, v. 49, p. 1583–1596, 2017.

BARROS, J.F.C.; CALADO, J.G. A cultura do milho. Évora: **Universidade de Évora**, 52 p, 2014.

BERGAMASCHI, H.; MATZENAUER, R. Parte II - **Cultivos temporários: milho. In: Instituto Nacional de Meteorologia. INMET. (Org.). Agrometeorologia dos cultivos O fator meteorológico na produção agrícola.** Brasília: INMET, p.240-260, 2009.

BOX, G.E.P.; JENKINS, G.M. **Time Series Analysis: Forecasting and Control**, Revised Edition, San Francisco: Holden Day, 1976.

BUSKE, T.C.; ROBAINA, A.D.; PEITER, M.X.; TORRES, R.R. Modelos agrometeorológicos para estimativa e comparativo de quebra de produtividade da cultura do milho. **Irriga**, v. 24, n. 4, p. 693-703, 2019.

BUSUIOC, A.; TOMOZEIU, R.; CACCIAMANI, C. Statistical downscaling model based on canonical correlation analysis for winter extreme precipitation events in the Emilia-Romagna region. **International Journal of Climatology**, v. 28, p. 449-464, 2008.

CARVALHO, M.; ÂNGELO, V.; OYAMA, M.D. Variabilidade da largura e intensidade da Zona de Convergência Intertropical atlântica: Aspectos observacionais. **Revista Brasileira de Meteorologia**, v. 28, p. 305–316, 2013.

CHOWDHURY, R.; CHU, P-S.; SCHROEDER, T.; COLASACCO, N. Seasonal sea-level forecasts by canonical correlation analysis – an operational scheme for the U.S.-affiliated Pacific Islands. **International Journal of Climatology**, v. 27, p. 1389-1402, 2007.

CHU, P-S.; HE, Y. Long-Range prediction of Hawaiian winter rainfall using Canonical Correlation Analysis. **International Journal of Climatology**, v. 14, p. 659-669, 1994.

CHU, P-S. Short-Term climate prediction of Mei-Yu rainfall for Taiwan using Canonical Correlation Analysis. **International Journal of Climatology**, v. 18, p. 215-224, 1998.

CORDEIRO, E.S.; FEDOROVA, N.; LEVIT, V. Synoptic and thermodynamic analysis of events with thunderstorms for alagoas state in a period of 15 years (1998–2012). **Revista Brasileira de Meteorologia**, v. 33, p. 685–694, 2018.

COSTA, R.L.; DE SOUZA, E.P.; SILVA, F.D.D.S. Aplicação de uma teoria termodinâmica no estudo de um Vórtice Ciclônico de Altos Níveis sobre o nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 29, p. 96–104, 2014.

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

CUNHA, A.P.M.A.; ALVALÁ, R.C.S.; NOBRE, C.A.; CARVALHO, M.A. Monitoring vegetative drought dynamics in the Brazilian semiarid Region. **Agricultural and Forest Meteorology**, v. 214, p. 494-505, 2015.

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

CUNHA, A.P.M.A.; ZERI, M.; LEAL, K.D.; COSTA, L.; CUARTAS, L.A.; MARENGO, J.A.; TOMASELLA, J.; VIEIRA, R.M.; BARBOSA, A.A.; CUNNINGHAM, C.; et al. Extreme Drought Events over Brazil from 2011 to 2019. **Atmosphere**, v. 10, p. 642, 2019.

DEVIDE, A.C.P.; RIBEIRO, R.L.D.; VALLE, T.L.; ALMEIDA, D.L.; CASTRO, C.M.; FELTRAN, J. C. Produtividade de raízes de mandioca consorciada com milho e caupi em sistema orgânico. **Bragantia**, v. 68, n. 1, p. 145-153, 2009.

DÍAZ, D.; VILLEGAS, N. Canonical Correlation between large scale climate oscillations and surface meteorological variables in Colombia. **Revista U.D.C.A Actualidad & Divulgación Científica**, v. 18 (2), p. 543 - 552, 2015.

EMBRAPA, **Cultivo do Milho**. 6^a edição Set./2010

ESQUIVEL A. Predictability of seasonal precipitation across major crop growing areas in Colombia. **Climate Services** Volume 12 Pages 36-47, December, 2018

FERREIRA, D.B.; MELLO, L.T.A.; LUCIO, P.S.; FORTES, L.T.G.; BALBINO, H.T.; SALVADOR, M.A.; SANTOS, L.A.R.S.; SILVA, F.D.S. Análise da influência da variabilidade da temperatura da superfície do mar sobre a produtividade de soja no Estado do Paraná utilizando o “Climate Predictability Tool”. **In: XIV Congresso Brasileiro de Meteorologia**, Florianópolis, 2006.

GARNETT, E.R.; KHANDEKAR, M.L. The impact of large-scale atmospheric circulations and anomalies on Indian monsoon droughts and floods and on world grain yields - a statistical analysis. **Agricultural and Forest Meteorology**, v. 61, p. 113-128, 1992.

GASPAR, N.A.; APARECIDO, L.E.O.; ROLIM, G.S.; SOUZA, P.S.; BOTELHO, T.G. Software for the management of weather stations and for agrometeorological calculations. **Australian Journal of Crop Science**, v.9 (6), p.545-551, 2015.

GOMES, H.B.; AMBRIZZI, T.; HERDIES, D.L.; HODGES, K.; DA SILVA, B.F.P. Easterly Wave Disturbances over Northeast Brazil: An Observational Analysis. **Advances in Meteorology**, v. 2015, p. 1–20, 2015.

GOMES, H.B.; AMBRIZZI, T.; DA SILVA, B.F.P.; HODGES, K.; DIAS, P.L.S.; HERDIES, D.L.; SILVA, M.C.L.; GOMES, H.B. Climatology of easterly wave disturbances over the tropical South Atlantic. **Climate Dynamics**, v. 53, p. 1393–1411, 2019.

HASTENRATH, S. Interannual Variability and Annual Cycle: Mechanisms of Circulation and Climate in the Tropical Atlantic Sector. **Monthly Weather Review**, v. 112, p. 1097–1107, 1984.

HASTENRATH, S.; GREISCHAR, L. Circulation mechanisms related to northeast Brazil rainfall anomalies. **Journal of Geophysical Research. Space Physics**. v.98, p. 5093–5102, 1993.

HASTENRATH, S. Exploring the climate problems of Brazil’s Nordeste: a review. **Climatic Change**, v. 112, p. 243–251, 2012.

HOLT, C.C. **Forecasting seasonals and trends by exponentially weighted moving averages**. ONR Research Memorandum, Carnegie Institute 52, 1957.

HOPKINS, W.G. **A New View of Statistics: Correlation Coefficient**. New York: **Internet Society for Sport Science**, 2009.

HOTELLING, H, 1936. Relations between two sets of variates. **Biometrika** 28, 321.

JOHANSSON, A.; BARNSTON, A.; SAHA, S.; VAN DEN DOOL, H.M. On the level and origin of seasonal forecast skill in northern Europe. **Journal of the Atmospheric Science**, v. 55, p. 103–127, 1998.

JUNENG, L.; TANGANG, F. Level and source of predictability of seasonal rainfall anomalies in Malaysia using canonical correlation analysis. **International Journal of Climatology**, v. 28, p. 1255-1267, 2008.

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

KAYANO, M.T.; ANDREOLI, R.V. Decadal variability of northern northeast Brazil rainfall and its relation to tropical sea surface temperature and global sea level pressure anomalies. **Journal of Geophysical Research**, v. 109, C11, 2004.

KAYANO, M.T.; ANDREOLI, R.V. Relationships between rainfall anomalies over northeastern Brazil and the El Niño–Southern Oscillation. **Journal of Geophysical Research: Space Physics**, v. 111, 13102, 2006.

KAYANO, M.T.; CAPISTRANO, V.P. How the Atlantic Multidecadal Oscillation (AMO) modifies the ENSO influence on the South American rainfall. **International Journal of Climatology**, v. 34, p. 162–178, 2014.

KOUSKY, V.E. Frontal Influences on Northeast Brazil. **Monthly Weather Review**, v. 107, p. 1140–1153, 1979.

KOUSKY, V.E.; GAN, M.A. Upper tropospheric cyclonic vortices in the tropical South Atlantic. **Tellus**, v. 33, p. 538–551, 1981.

KOUSKY, V.E.; KAYANO, M.T. Principal Modes of Outgoing Longwave Radiation and 250-mb Circulation for the South American Sector. **Journal of Climate**, v. 7, p. 1131–1143, 1994.

LANDMAN, W.A.; MASON, S.J. Operational Long-Lead prediction of South African rainfall using Canonical Correlation Analysis. **International Journal of Climatology**, v. 19, p. 1073-1090, 1999.

LIM, Y.; JO, S.; LEE, J.; OH, H-S.; KANG, H-S. An improvement of seasonal climate prediction by regularized canonical correlation analysis. **International Journal of Climatology**, v. 32, p. 1503-1512, 2012.

LUCIO, P.S.; SILVA, F.D.S.; FORTES, L.T.G.; SANTOS, L.A.R.; FERREIRA, D.B.; SALVADOR, M.A.; BALBINO, H.T.; SARMANHO, G.F.; SANTOS, L.S.F.C.; LUCAS, E.W.M.; BARBOSA, T.F.; DIAS, P.L.S. Um Modelo Estocástico Combinado de Previsão Sazonal para a Precipitação no Brasil. **Revista Brasileira de Meteorologia**, v. 25, p. 70-87, 2010.

MARENGO, J.A.; TORRES, R.R.; ALVES, L.M. Drought in Northeast Brazil-past, present, and future. **Theoretical and Applied Climatology**, v. 129, p. 1189-1200, 2016.

MARENGO, J.A.; ALVES, L.M.; ALVALA, R.C.C.; CUNHA, A.P.M.A.; BRITO, S.B.; MORAES, O.L.L. Climatic characteristics of the 2010–2016 drought in the semiarid

Northeast Brazil region. **Anais da Academia Brasileira de Ciências**, v. 90, p. 1973–1985, 2018.

MARTÍN, N.F.; BOLLERO, G.; BULLOCK, D.G. Associations between field characteristics and soybean plant performance using canonical correlation analysis. **Plant and Soil**, v. 273, p. 39–55, 2005.

MARTINS, M.A.; ALVALÁ, R.C.S.; TOMASELLA, J. Modelos de produtividade agrícola aplicados à agricultura de sequeiro: Limitações e vantagens para avaliação de colapso de safras. **ACSA – Agropecuária Científica no Semiárido**, v.10 (4), p 41-48, 2014.

MARTINS, M.A.; HOCHRAINER-STIGLER, S.; PFLUG, G. Vulnerability of Agricultural Production in the Brazilian Semi-Arid: An Empirical Approach including Risk. **Journal of Integrated Disaster Risk Management**, v. 7(1), p. 1 - 23, 2017.

MARTINS, M.A.; TOMASELLA, J.; RODRIGUEZ, D.A.; ALVALÁ, R.C.; GIAROLLA, A.; GAROFOLO, L.L.; JÚNIOR, J.L.S.; PAOLICCHI, L.T.; PINTO, G.L. Improving drought management in the Brazilian semiarid through crop forecasting. **Agricultural Systems**, v. 160, p. 21-30, 2018.

MARTINS, E.S.P.R.; COELHO, C.A.S.; HAARSMA, R.; OTTO, F.E.L.; KING, A.D.; VAN OLDENBORGH, G.J.; KEW, S.; PHILIP, S.; JÚNIOR, F.C.V.; CULLEN, H. A multimethod attribution analysis of the prolonged northeast Brazil hydrometeorological drought (2012–16). **Bulletin of the American Meteorological Society**, v. 99, p. 65-69, 2018.

MARTINS, M. A.; TOMASELLA, J.; DIAS, C. G. Maize yield under a changing climate in the Brazilian Northeast: Impacts and adaptation. **Agricultural Water Management**, v. 216, p. 339-350, 2019.

MELO, T.M.; WOTTRICH, I.; LOUZADA, J.A.; HELFER, F. Avaliação do atendimento da demanda hídrica da cultura do milho através da subirrigação. **Revista Brasileira de Agricultura Irrigada**, v.4 (4), p.226–233, 2010.

MOURA, A.D.; SHUKLA, J. On the dynamics of droughts in northeast Brazil: Observations, theory and numerical experiments with a general circulation model. **Journal of Atmospheric Sciences**, v. 38, p. 2653–2675, 1981.

OLIVEIRA, G.C.S; ALVES, K.M.A.S.; NÓBREGA, R.S. Sistemas Atmosféricos Dinâmicos de Grande Escala Responsáveis pela Ocorrência de Chuva no Nordeste Brasileiro. In: **II Workshop de Mudanças Climáticas e Recursos Hídricos de Pernambuco**, 2010, Recife. Mudanças Climáticas e Recursos Hídricos. Recife, 2010.

OLIVEIRA, C.P.; KAYANO, M.T. EFEITOS DO ENOS NA PRECIPITAÇÃO NA AMÉRICA DO SUL ANTES E DEPOIS de 1977. **Acta de las Jornadas Científicas de la Asociación Meteorológica Española**. Edição 30, 2020.

PRATES, J.E.; SEDYAMA, G.C.; VIEIRA, H.A. Clima e produção agrícola. **Informe Agropecuário**, Belo Horizonte-MG, v. 12, n. 138, p. 18 - 22, 1986.

RADIN, B.; BERGAMASCHI, H.; SANTOS, A.O.; BERGONCI, J.I.; FRANÇA, S. Evapotranspiração da cultura do milho em função da demanda evaporativa atmosférica e do crescimento das plantas. **Pesquisa Agropecuária Gaúcha**, v. 9 (1-2), p. 7-16, 2003.

RAO, V.B.; DE LIMA, M.C.; FRANCHITO, S.H. Seasonal and Interannual Variations of Rainfall over Eastern Northeast Brazil. **Journal of Climate**, v. 6, p. 1754–1763, 1993.

RENATO, N.S.; SILVA, J.B.L.; SEDIYAMA, G.C.; PEREIRA, E.G. Influência dos métodos para cálculo de graus-dia em condições de aumento de temperatura para as culturas de milho e feijão. **Revista Brasileira de Meteorologia**, v.28 (4), p. 382-388, 2013.

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

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

SALVADOR, M.A.; BRITO, J.I.B. Trend of annual temperature and frequency of extreme events in the MATOPIBA region of Brazil. **Theoretical and Applied Climatology**, v. 133, p. 253-261, 2018.

SBRUSSI, C.A.G.; ZUCARELI, C. Germinação de sementes de milho com diferentes níveis de vigor em resposta à diferentes temperaturas. **Semina: Ciências Agrárias**, Londrina, v. 35 (1), p. 215-226, 2014.

SCHWERZ, F.; CARON, B.O.; ELLI, E.F.; OLIVEIRA, D.M.; MONTEIRO, G.C.; SOUZA, V.Q. Avaliação do efeito de doses e fontes de nitrogênio sobre variáveis morfológicas, interceptação de radiação e produtividade do girassol. **Revista Ceres**, Viçosa, v. 63 (3), p. 380-386, 2016.

SILVA, J.W.; SOARES, L.; FERREIRA, P.V.; SILVA, P.P.; SILVA, M.J.C. Canonical correlations of agro-industrial characteristics in sugarcane. **Acta Scientiarum. Agronomy**, v. 29(3), p. 345-349, 2007.

SILVA, V.B.S.; KOUSKY, V.E.; SILVA, F.D.S.; SALVADOR, M.A.; ARAVEQUIA, J.A. The 2012 severe drought over Northeast Brazil. **Bulletin of the American Meteorological Society**, v. 94, S240, 2013.

SILVA, F. D. S.; ROCHA JUNIOR, R. L.; COSTA, R. L. ; SILVA, D. F. ; PEREIRA, M. P. S. . SEALBA, **Características Climáticas da Nova Fronteira Agrícola Brasileira**. In: André Becker Nunes; Glauber Lopes Mariano. (Org.). *Meteorologia em Tópicos-Volume 7*. 1ed.: DR LTDA, 2020, v. 7, p. 200-246.

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

SOUZA, A.E.; REIS, J.G.M.; RAYMUNDO, J.C.; PINTO, R.S. Estudo da produção do milho no Brasil. **South American Development Society Journal**, v. 4(11), p. 182–194, 2018.

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

TORCANO, E.M.M.; REISEN, V.A. The Use of Canonical Correlation Analysis to Identify the Order of Multivariate ARMA Models: Simulation and Application. **Journal of Forecasting**, v. 19, p. 441-455, 2000.

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

WINTERS, P.R. Forecasting sales by exponentially weighted moving averages. **Management Science**, v. 6, p. 324-342, 1960.

XAVIER, T.M.B. Interrelações Entre Eventos ENOS (ENSO), a ZCIT (ITCZ) no Atlântico e a Chuva nas Bacias Hidrográficas do Ceará. **RBRH - Revista Brasileira de Recursos Hídricos**, v. 2, n. 2, 2003.

XAVIER, T. DE MA. B. S.; XAVIER, A. F. S. **O Planeta Terra: Aquecimento Global e Mudanças Climáticas**. **BSBMET**, v.30, n.4, p.73-79, 2007.

ZAKARIA H. Assessment of Better Prediction of Seasonal Rainfall by Climate Predictability Tool Using Global Sea Surface Temperature in Bangladesh. **Asian Journal of Advanced Research and Reports**, v. 4, n. 4, p. 1-13, 2019.