

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

NATHÁLIA BISSAQUE PESSOTA

**UMA ABORDAGEM HÍBRIDA DINÂMICO-ESTATÍSTICA PARA A
PREVISÃO CLIMÁTICA DO NORDESTE DO BRASIL**

MACEIÓ – AL

2024

NATHÁLIA BISSAQUE PESSOTA

**UMA ABORDAGEM HÍBRIDA DINÂMICO-ESTATÍSTICA PARA A
PREVISÃO CLIMÁTICA DO NORDESTE DO BRASIL**

Trabalho de Dissertação apresentado como requisito para obtenção de aprovação no Mestrado Acadêmico do Programa de Pós-Graduação em Meteorologia, do Instituto de Ciências Atmosféricas, da Universidade Federal de Alagoas.

Orientador: Professor Dr. Fabrício Daniel dos Santos Silva.

Co-Orientador: Dra. Rafaela Lisboa Costa.

MACEIÓ – AL

2024

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

Bibliotecário: Jone Sidney A. de Oliveira – CRB-4 – 1485

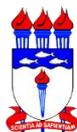
P475a Pessota, Nathália Bissaque.
Uma abordagem híbrida dinâmico-estatística para a previsão climática do
nordeste do Brasil / Nathália Bissaque Pessota. – 2024.
83 f. : il.

Orientadora: Fabrício Daniel dos Santos Silva.
Coorientador: Rafaela Lisboa Costa..
Dissertação (Mestrado em Meteorologia) – Universidade Federal de Alagoas.
Instituto de Ciências Atmosféricas. Maceió, 2024.

Bibliografia: f. 66-83.

1. Previsões Climáticas. 2. NMME. 3. Precipitação. 4 Ensembles. I. Título.

CDU: 551.5



UNIVERSIDADE FEDERAL DE ALAGOAS
INSTITUTO DE CIÊNCIAS ATMOSFÉRICAS
COORDENAÇÃO DO MESTRADO EM METEOROLOGIA

ATA DE APRESENTAÇÃO PÚBLICA DE DISSERTAÇÃO DE MESTRADO

Aos trinta dias do mês de abril do ano de dois mil e vinte e quatro, às catorze horas, por Videoconferência, Campus A. C. Simões da Universidade Federal de Alagoas (UFAL), perante a Banca Examinadora composta pelo Prof. Dr. Fabrício Daniel dos Santos Silva– Orientador, Profa. Dra. Rafaela Lisboa Costa – Coorientadora, Prof. Dr. Helber Barros Gomes - Membro Interno e Profa. Dra. Sandra Isay Saad - Membro Externo, a senhora *Nathália Bissaque Pessota* sob a orientação do Prof. Dr. Fabrício Daniel dos Santos Silva–, apresentou publicamente uma dissertação intitulada: “**UMA ABORDAGEM HÍBRIDA DINÂMICO-ESTATÍSTICA PARA A PREVISÃO CLIMÁTICA DO NORDESTE DO BRASIL.**” número de série, **MET-UFAL-MS-204** 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 a senhora *Nathália Bissaque Pessota* *aprovada*. 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, Helber Barros Gomes, 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, 30 de abril de 2024.

Prof. Dr. Helber Barros
Gomes
(Coordenador/Membro
Interno)

Documento assinado digitalmente
gov.br HELBER BARROS GOMES
Data: 30/04/2024 19:03:44-0300
Verifique em <https://validar.iti.gov.br>

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

Documento assinado digitalmente
gov.br FABRICIO DANIEL DOS SANTOS SILVA
Data: 30/04/2024 15:57:23-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Rafaela Lisboa Costa
(Coorientadora)

Documento assinado digitalmente
gov.br RAFAELA LISBOA COSTA
Data: 30/04/2024 15:52:04-0300
Verifique em <https://validar.iti.gov.br>

Documento assinado digitalmente
gov.br SANDRA ISAY SAAD
Data: 30/04/2024 16:18:06-0300
Verifique em <https://validar.iti.gov.br>

DEDICATÓRIA

Dedico primeiramente a Deus essa grandiosa conquista, por me conceder saúde, graça e sabedoria todos os dias da minha vida.

Ao meu esposo Marcos Alves por todo apoio, paciência, incentivo e amor que sem dúvidas me impulsionou a chegar até aqui, todo o meu carinho a você.

A minha Mãe Liliane Bissaque por todo seu ensino, zelo e discernimento, acreditando no meu potencial e olhando sempre para o alvo final, me encorajando nos momentos difíceis e sendo todos os dias minha melhor amiga.

Ao meu Pai Silvio Medeiros, por sempre proteger nossa família se sacrificando imensamente e não medindo esforços para o meu melhor, essa vitória também é sua.

Ao meu irmão Samuel Bissaque pelo carinho e amor que temos um pelo outro, mantenho minha realização de irmã mais velha em você e espero que essa vitória seja orgulho e respaldo para sua vida acadêmica/profissional.

Aos meus avós Miguel e Mariza, incluo aqui também meu Tio Mateus, pelo apoio incondicional e imerecido que sempre obtive por eles, seja por palavras de conforto e encorajamento, ou por orações fortificadas na palavra de Cristo que sempre me manteve de pé, essa vitória é de vocês também.

A toda minha família Bissaque e Pessota, o apoio e a força que obtive por vocês foram cruciais até essa chegada, todo meu amor e respeito.

AGRADECIMENTOS

Agradeço ao meu Deus por tudo, toda honra, glória e louvor seja a Ele para sempre. Obrigada meu amor Marcos Alves por se dedicar pelo nosso futuro todos os dias, me dando apoio e incentivo, você foi fundamental para essa conquista se concretizar, te amo imensamente.

Agradeço aos meus pais Silvio e Liliane, e ao meu irmão Samuel, por serem minha base e sempre me ajudarem nos meus sonhos, com certeza sem vocês seria impossível concluir essa missão, obrigada por todo incentivo.

A toda minha família, em especial meus avós Miguel e Mariza, Sadi e Elza e ao meu tio Mateus, meu eterno agradecimento, por todo carinho nessa jornada, sei que toda oração chegou ao trono do Pai Celestial e me impulsionou a chegar até aqui, a vocês todo meu carinho e amor.

A minha amiga de turma Maiane Rodrigues, que Deus colocou no meu caminho para ser minha companheira nas horas difíceis e parceira constante nos dias de alegria, compartilho contigo essa conquista pois tens parte dela, meu muito obrigada sempre.

Agradeço ao meu orientador Fabrício Daniel dos Santos Silva, por todos os seus ensinamentos, compreensão e paciência, sua dedicação foi de fundamental importância para a realização dessa pesquisa, obrigada.

Agradeço a FAPEAL pela contemplação da bolsa cota CAPES, tal incentivo ajudou na árdua jornada ao longo de todo o curso do mestrado. Sou grata a todos que participaram direta e indiretamente para a realização deste.

Consagre ao Senhor tudo o que você faz e seus planos serão bem sucedidos.

Provérbios 16:3

RESUMO

A previsão climática ganha cada vez mais protagonismo em atividades de planejamento relacionadas a diferentes setores econômicos, como agricultura, energia, recursos hídricos, transporte e turismo. Há diferentes modelos climáticos e diferentes técnicas para levar essa informação até a sociedade, que demanda por previsões que possibilitem tomadas de decisões. No entanto, apesar dos avanços ainda se faz necessário pesquisar metodologias que consigam melhorar e aumentar a confiabilidade de previsões climáticas provenientes de modelos. Diante disso, essa pesquisa teve como principal objetivo aplicar uma técnica de pós-processamento às saídas dos modelos climáticos que compõem o projeto North-American MultiModel Ensemble (NMME). A área de estudo é a região Nordeste do Brasil (NEB), e a técnica usada para calibrar as previsões foi a Análise de Correlações Canônicas (ACC). A ACC foi empregada para calibrar as previsões mensais da precipitação acumulada para o NEB, usando a previsão do modelo como variável preditora e a precipitação observada como o preditando, confrontando um *hindcast* de 30 anos de previsão com as observações do mesmo período, de 1991 a 2020. Os resultados mostram que as saídas diretas das previsões dos modelos do NMME apresentam vieses significativos quando se compara a climatologia dos modelos e a observada, e que após a calibração com ACC, esses vieses são corrigidos e as correlações entre previsões e observações aumentam significativamente, além de haver redução nos erros das previsões. Após essa etapa, verificou-se para uma defasagem de até três meses de previsão para determinado mês, quais modelos apresentaram melhores resultados, a fim de combiná-los em um conjunto limitado de modelos para gerar previsões mais confiáveis para o NEB. Tais médias de conjuntos (ensembles) mostraram uma correlação ainda maior que a dos modelos individuais mesmo após o pós-processamento com ACC.

Palavras-chave: Previsões climáticas, NMME, Precipitação, ensembles.

ABSTRACT

Climate forecasting is gaining more and more prominence in planning activities related to different economic sectors, such as agriculture, energy, water resources, transport and tourism. There are different climate models and different techniques to convey this information to society, which require variations to enable decision-making. However, despite advances, it is still necessary to research methodologies that can improve and increase the reliability of specific climate variation in models. Therefore, the main objective of this research was to apply a post-processing technique to the outputs of the climate models that make up the North-American MultiModel Ensemble (NMME) project. The study area is the Northeast region of Brazil (NEB), and the technique used to calibrate the variations was the Canonical Correlation Analysis (CCA). The CCA was used to calibrate the monetary variations of the accumulated variations for the NEB, using the model forecast as the predictor variable and the observed occurrences as the predictor, comparing a hindcast of 30 years of forecast with observations from the same period, from 1991 to 2020. The results show that the direct outputs of NMME model corrections present significant views when comparing model and observed climatology, and that after flexibility with ACC, these views are corrected and correlations between observations and observations increase significantly, in addition. there will be a reduction in variation errors. After this step, a lag of up to three months of forecasting for a given month was provided, which models presented the best results, in order to combine them into a limited set of models to generate more specific efficiency for the NEB. Such ensemble media (ensembles) showed an even greater demonstration than that of individual models even after post-processing with CCA.

Keywords: Climate predictions, NMME, Rainfall, ensembles.

LISTA DE FIGURAS

Figura 1 - Unidades federativas da região Nordeste	18
Figura 2 - (a) Centróides dos municípios do NEB e (b) Distribuição geográfica das 96 estações meteorológicas convencionais nos estados do NEB	32
Figura 3 - Esquema ilustrativo das etapas utilizadas para a calibração e previsão da precipitação para o NEB a partir da precipitação do NMME.....	41
Figura 4 - Climatologia mensal da precipitação (mm) no NEB com dados do INMET no período 1991-2020.....	47
Figura 5 - Climatologia mensal da precipitação (mm) no NEB com dados da análise gradeada de Xavier no período 1991-2020.....	48
Figura 6 - Diferença entre a climatologia mensal obtida com dados da análise gradeada de Xavier e observações do INMET para a precipitação no NEB no período 1991-2020	49
Figura 7 - (a) Viés, (b) Correlação, (c) MAE e (d) RMSE, calculados entre observações e análise gradeada de Xavier para a precipitação mensal do NEB no período 1991-2020	50
Figura 8 - Painel de comparação das climatologias de Xavier (observada) e bruta dos modelos para o mês de abril no período de 1991 a 2020.	53
Figura 9 – Painel comparativo de correlação com os dados de Xavier (1991 a 2020), coluna da esquerda são os modelos brutos e coluna da direita os modelos calibrados com ACC.....	58
Figura 10 - Painel de correlação global mensal dos modelos calibrados	62

LISTA DE TABELAS

Tabela 1 - Relação entre eventos ENOS e Secas no Nordeste do Brasil.....	22
Tabela 2 - Classificação dos intervalos de correlação e definição da relação entre os dados simulados por um modelo e os dados observados	43
Tabela 3 - Meses do ano x Melhor lag de previsão	63
Tabela 4 - Participação de cada modelo nas 3 maiores correlações	63
Tabela 5 - Correlação dos Ensembles.....	64

LISTA DE ABREVIATURAS E SIGLAS

ACC	Análise de Correlações Canônicas
ACGMs	Modelos de Circulação Global Atmosférico
ACP	Análise de Componentes Principais
BS	Brier Score
CC	Cargas canônicas
CCC	Cargas Canônicas Cruzadas
CCSM4	Community Climate System Model version 4
CFSv2	Climate Forecast System versão 2
CGMs	Modelos de Circulação Global
CMC	(Canadian Meteorological Centre).
CMC1	CanCM3
CMC2	CanCM4
CPC	Climate Prediction Center
Cov	Covariância
ECMWF	European Centre for Medium-Range Weather Forecasts
ENSO	El niño-Oscilação Sul
EOF	Empirical Orthogonal Function
ETA	Regional model CPTEC and NCEP .
EUA	Estados Unidos da América
FOE	Função ortogonal empírica
GDPFS	Sistema Global de Processamento de Dados e Previsão
GEEs	Gases do efeito estufa
GEOS-5	Goddard Earth Observing System versão 5
GFDL	Geophysical Fluid Dynamics Laboratory
GFDL_FLOR	Forecast-oriented Low Ocean Resolution.
GFDL_SPEAR	Seamless System for Prediction and EARth System Research.
HCM	Hybrid Coupled Models
HSS	Heidke Skill Score

IMD	Departamento Meteorológico da Índia
INMET	Instituto Nacional de Meteorologia
IPCC	Painel Intergovernamental sobre Mudanças Climáticas
IRI	International Research Institute for Climate Society
ISMR	Indian Summer Monsoon Rainfall
KMA	Korea Meteorological Agency
MAE	Erro médio absoluto
MBE	Mean Bias Error
MJO	Oscilação Madden-Julian
MM5	Mesooscale Model 5
NASA-GEOSS2S	Goddard Earth Observing System AOGCM
NAO	Oscilação do Atlântico Norte
NASA	National Aeronautics and Space Administration
NCAR	National Center for Atmospheric Research
NCEP	National Centers for Environmental Prediction
NE	Nordeste
NEB	Nordeste do Brasil
NMME	North American Multi-Model Ensemble
NPO	Oscilação do Pacífico Norte
NOAA	National Oceanic and Atmospheric Administration
OMM	Organização Meteorológica Mundial
OS	Oscilação do Sul
PBMC	Painel Brasileiro de Mudanças Climáticas
PNA	Pacífico Norte-Americano
r	Coefficiente de correlação de Pearson
RAMS	Regional Atmospheric Modeling System
RCOFs	Fóruns Regionais de Perspectivas Climáticas
RLM	Regressão Linear Múltipla
RMSE	Erro quadrático médio

RSM	Reynolds Stress Model
SEALBA	Sergipe, Alagoas e Bahia
TAO	Oceano de Atmosfera Tropical
TOGA	Oceanos Tropicais e Atmosfera Global
TSM	Temperatura da Superfície do Mar
VC	Variável canônica
WMO	World Meteorological Organization
ZCIT	Zona de Convergência Intertropical

SUMÁRIO

1. INTRODUÇÃO	6
1.1 OBJETIVO GERAL	9
1.2 OBJETIVOS ESPECÍFICOS	9
2. REVISÃO BIBLIOGRÁFICA	10
2.1 Previsões Climáticas Sazonais: evolução histórica	10
2.2 Componentes da Variabilidade Climática	13
2.3 Mudanças Climáticas	15
2.4 Nordeste brasileiro	17
2.5 El Niño-Oscilação Sul e os efeitos no Nordeste brasileiro	20
2.6 Modelos Empíricos	22
2.7 Análise de Correlações Canônicas (ACC)	23
2.8 Modelos dinâmicos	24
2.9 Downscaling	27
2.10 Abordagem híbrida de previsões climáticas	29
3. MATERIAL E MÉTODOS	31
3.1 Dados observados	31
3.2 Dados do NMME	32
3.2.1 Modelos individuais do NMME	33
3.2.2 <i>Hindcasts</i> do NMME	34
3.2.3 Organização dos dados para calibração do NMME	35
3.2.4 Calibração de previsões climáticas com ACC	36
3.3 Fundamentação teórica da ACC	37
3.4 Ferramenta de previsibilidade	39
3.5 Índices de verificação	41
3.5.1 Erro Médio Absoluto (MAE)	42
3.5.2 Erro quadrático médio (RMSE)	42
3.5.3 Correlação de Pearson (<i>r</i>)	43
4. RESULTADOS	45
4.1 Análise dos dados de Xavier para o Nordeste	45
4.2 Climatologia bruta dos modelos NMME	50
4.3 Calibração dos modelos com ACC	55
4.4 Matrizes de correlação com técnica ACC	60
5. CONCLUSÕES	65
REFERÊNCIAS BIBLIOGRÁFICAS	67

1. INTRODUÇÃO

Previsões precisas podem salvar vidas, apoiar o gerenciamento de emergências, bem como, mitigar os efeitos advindos do clima, evitando perdas econômicas de alto impacto, além de gerar receitas financeiras substanciais – por exemplo, nos ramos de energia, agricultura, transporte e lazer. Os benefícios superam em muito os custos de investimento em pesquisa científica essencial, instalações de supercomputação, satélites e outros programas observacionais necessários para produzir tais previsões climáticas (BAUER *et al.*, 2015).

Nos últimos quarenta anos, o progresso nos sistemas e melhorias observacionais, a compreensão e modelagem dos vários componentes da Terra, os avanços contínuos de computação em previsão do clima têm tomado lugar em grandes centros operacionais do mundo todo (BAUER *et al.*, 2015).

É importante destacar que podemos avaliar objetiva e quantitativamente a precisão das previsões climáticas mais confiáveis, uma vez que podemos comparar diariamente as previsões com o que realmente acontece. Por exemplo, a capacidade de prever o tempo com antecedência de 3 a 10 dias está em constante evolução. A cada década, observamos um aumento de aproximadamente um dia nesse intervalo de previsão. Isso significa que a precisão da previsão de 6 dias de hoje é equivalente à precisão da previsão de 5 dias realizada há dez anos. A preditiva habilidade nos hemisférios Sul e Norte é quase igual hoje, graças ao efetivo uso de informações observacionais de dados de satélite fornecendo cobertura global (WMO, 2019).

No Brasil, as variações dos regimes de precipitação se estendem de norte a sul, devido à grande extensão territorial do país, onde encontramos uma enorme diversidade de climas e características regionais. A região Nordeste do Brasil (NEB) é suscetível às variações climáticas, pois apresenta longos períodos de escassez de água devido às secas. O regime de precipitação pluvial nessa área depende de vários sistemas atmosféricos que atuam na costa leste do Nordeste, sendo mais frequentes os seguintes: zona de convergência intertropical, brisas marítimas e terrestres, vórtices ciclônicos de altos níveis e distúrbios ondulatórios de leste (UVO, 1989; MOLION e BERNARDO., 2002; REBOITA *et al.*, 2002; CARVALHO e OYAMA., 2013; COSTA *et al.*, 2014; GOMES

et al., 2015; GOMES *et al.*, 2019; ANJOS *et al.*, 2019; LYRA *et al.*, 2020; CAVALCANTE *et al.*, 2020; VEBER *et al.*, 2020; REPINALDO *et al.*, 2020).

Para Diaz *et al.* (1998) determinadas regiões da América do Sul possuem variabilidade climática relacionada em parte à variabilidade interanual da Temperatura da Superfície do Mar (TSM) nos Oceanos Pacífico e Atlântico, podendo influenciar diretamente na produtividade agrícola anual, causando perdas ou ganhos em diferentes regiões. No nordeste do Brasil, as anomalias na Temperatura da Superfície do Mar (TSM) nos oceanos Pacífico Equatorial e Atlântico Tropical têm um impacto significativo no padrão de circulação atmosférica global, conhecido como Célula de Walker. Essas anomalias afetam a intensidade e o padrão dos ventos alísios e também deslocam latitudinalmente a Zona de Convergência Intertropical (ZCIT). Como resultado, ocorrem mudanças nos padrões de precipitação na região nordeste do Brasil. Estudos como os de Nobre *et al.* (1986), Marengo (2006) e Kayano e Andreoli (2009) têm destacado essa relação entre as anomalias de TSM e as mudanças nos acumulados de precipitação nessa região.

Os avanços na previsão do tempo e do clima complementam os destaques da ciência e infraestrutura operacional para previsões em prazos mais longos. Em meados de 1990 as primeiras gerações de sistemas dinâmicos de previsão sazonal foram implementadas em centros operacionais (JI *et al.*, 1994; STOCKDALE *et al.*, 1998).

Previsões climáticas sazonais de rotina nos níveis global e regional agora fornecem informações críticas para o bem-estar econômico da sociedade, igualmente, para mitigar perdas de vida e propriedade, principalmente em setores que irão potencialmente usar essas previsões e responder às suas necessidades (TROCCOLI *et al.*, 2008).

Segundo o World Meteorological Organization (WMO) *edição 2019*, o desenvolvimento de previsões sazonais e a infraestrutura associada preenche a necessidade do usuário de informações preditivas sobre escalas de tempo sazonais que podem ser usadas para fins de tomada de decisão. No entanto, previsões mais precisas de precipitação acumulada e temperatura média para os próximos três meses representam um desafio para os principais centros que desenvolvem previsões climáticas globais. Os benefícios de previsões mais confiáveis são estratégicos para os setores de recursos hídricos, bem como para a tomada de decisão dos gestores de emergência no

planejamento e mitigação dos impactos de secas e enchentes, por exemplo. A incerteza da previsão climática leva a uma cadeia de incertezas em relação à produtos específicos que a utilizam como principal entrada, como os relativos à modelagem hidrológica e à previsão de safras (CLARK e SLATER, 2006; KAVETSKI *et al.*, 2006; ESQUIVEL *et al.*, 2018).

Nesse sentido, iniciativas de agregação de modelos (ex: produtos de previsões climáticas do North American Multi-Model Ensemble - NMME) ou aprimoramento de sistemas de modelagem de ambientes terrestres (ex: produtos de previsões climáticas do European Centre for Medium-Range Weather Forecasts - ECMWF) constituem os mais recentes avanços na tentativa de melhorar cada vez mais a confiabilidade das previsões, bem como seu horizonte de previsibilidade (previsões para mais de três meses/trimestres à frente) e resolução temporal (previsões sazonais para intra-sazonais). Mesmo com avanços notáveis nessas duas direções, ainda existem várias incertezas nos resultados de previsão (MA *et al.*, 2014; NAJAFI e MORADKHANI, 2015; AHMADALIPOUR *et al.*, 2017) que dão espaço para o desenvolvimento/aplicação de técnicas de pós-processamento que permitem aumentar a confiabilidade dessas previsões (BARNSTON e TIPPET, 2017).

Nesse sentido, será aplicada nessa pesquisa a técnica de Análise de Correlações Canônicas (ACC), como método de *downscaling* estatístico para calibração e validação de previsões mensais do NMME (BECKER *et al.*, 2013; 2020) para as precipitações acumuladas mensais da região Nordeste do Brasil. A ACC é uma técnica de estatística multivariada que correlaciona dois conjuntos de dados, de tal forma que essa correlação seja maximizada pelas componentes principais de cada conjunto de dados. A vantagem da técnica de ACC está no fato de a mesma possibilitar a busca de padrões de oscilação conjunta entre dois ou mais campos físicos.

Assim, o principal objetivo deste trabalho é avaliar os vieses das previsões brutas da precipitação acumulada mensal do NMME para o NEB e a melhoria imposta nessas previsões após pós-processamento com ACC. Os dados observados de superfície usados nas etapas de treinamento e verificação são oriundos na análise gradeada de Xavier *et al.* (2022), uma vez que há muitos problemas em séries pluviométricas de estações meteorológicas, os principais relacionados à controle de qualidade insuficiente, falhas e

interrupção no funcionamento das estações, limitando a continuidade de séries temporais (CARVALHO, 2020; SILVA *et al.*, 2022).

1.1 OBJETIVO GERAL

Regionalizar previsões climáticas de modelos do projeto norte-americano NMME para o NEB, reduzindo os vieses sistemáticos e aumentando a precisão para fins de prognósticos operacionais de precipitação mensal, com até três meses de antecedência.

1.2 OBJETIVOS ESPECÍFICOS

(a) Identificar o nível de diferenças entre a climatologia observada e a dos modelos individuais do NMME, e analisá-las por meio de diferentes parâmetros estatísticos;

(c) Verificar quais modelos apresentam o melhor desempenho após o pós-processamento com ACC, para cada mês do ano, e com quantos meses de antecedência;

(d) Analisar se a combinação de previsões oriundas dos melhores modelos gera uma previsão com menores vieses e menores erros.

2. REVISÃO BIBLIOGRÁFICA

2.1 Previsões Climáticas Sazonais: evolução histórica

A previsão climática sazonal ou comumente conhecida como previsão climática de longo prazo, fornece informações úteis sobre as condições climáticas médias esperadas para o período de 1 a 6 meses, distinguindo-se, desta forma, da previsão de tempo que fornece informações das condições atmosféricas para escalas de horas a dias. Portanto, em termos sazonais, não há habilidade em prever o dia que uma dada localidade terá precipitação, tempestade, temperaturas extremas, passagens de sistemas frontais, entre outros fenômenos, mas sim, habilidade em prever anomalias médias para períodos de 3 meses, pois, as previsões sazonais são probabilísticas, com probabilidades que podem ser estimadas a partir de um conjunto de previsões obtidas de modelos climáticos, dinâmicos (global e regional) ou estatísticos (WMO, 2019).

Em termos de evolução, a primeira previsão sazonal operacional de chuvas de monções de verão indiano para a região que cobre toda a Índia e Birmânia aconteceu após uma fome devastadora durante o final da década de 1870, emitida em 4 de junho de 1886 usando um método empírico por Henry Francis Blanford, o primeiro chefe do Departamento Meteorológico da Índia (IMD) estabelecido em 1875.

A suposição utilizada para esta primeira previsão foi baseada na extensão e espessura da neve do Himalaia, que por sua vez, influencia as condições climáticas sobre as planícies do noroeste da Índia (BLANFORD, 1884). Blanford usou essa relação para preparar previsões sazonais experimentais de 1882 a 1885 antes de tentar a primeira previsão operacional em 1886. Após esse marco, a previsão sazonal de chuvas de monções tornou-se uma responsabilidade operacional do IMD.

Em 1895 John Eliot sucedeu Blanford como chefe do IMD, em sua trajetória aplicou os métodos como a análise de ano análogo para a previsão sazonal de chuvas de monções de verão indiano (Indian Summer Monsoon Rainfall - ISMR) e no período de 1904-1924 com esforços para melhorar tais previsões o então diretor Geral do IMD, Gilbert T. Walker, percebendo as complexidades do problema de previsão, iniciou estudos sistemáticos para desenvolver técnicas mais precisas para previsão sazonal (WALKER, 1908).

Nos anos 1910, 1914 e 1923, Walker realizou também extensos estudos de variações mundiais para parâmetros climáticos, como chuva, temperatura, pressão e

assim por diante. A busca por preditores levou Walker a identificar três variações em grande escala nos padrões de pressão global: a Oscilação do Atlântico Norte (NAO), a Oscilação do Pacífico Norte (NPO) e a Oscilação do Sul (SO). Walker também introduziu o conceito de correlação e regressão pela primeira vez na previsão sazonal para remover a subjetividade das técnicas anteriores. A primeira previsão objetiva oficial foi emitida em 1909 para a precipitação sazonal das monções em toda a Índia com base na técnica de regressão.

A SO trata-se de uma gangorra entre a pressão do nível do mar no Taiti e Darwin, foi mais posteriormente ligada ao aquecimento incomum das águas superficiais no leste do Oceano Pacífico tropical, ou El Niño, por JACOB Bjerknes na década de 60 (BJERKNES, 1966, 1969). Bjerknes, e posteriormente outros, definiram esses fenômenos ligados a oceano-atmosfera como El Niño-Oscilação Sul (ENSO).

Podemos mencionar que, após os eventos de El Niño de 1972/1973, bem como os de La Niña de 1973/1974, observou-se fases opostos do ENOS e que geraram impactos significativos nos padrões de temperatura e precipitação em todo o mundo, sendo mais pronunciados nas regiões tropicais. Já o evento de El Niño de 1982/1983 e suas anomalias climáticas regionais associadas (ROPELEWSKI E HALPERT, 1987; RASMUSSEN E CARPENTER, 1983) resultaram no reconhecimento de que o fenômeno ENSO acoplado oceano-atmosfera é o modo dominante da variabilidade climática interanual da Terra (GODDARD *et al.*, 2001).

Foram essas observações apoiadas por vários estudos teóricos (CHARNEY E SHUKLA, 1981; PALMER E ANDERSON, 1994; BARNSTON *et al.*, 1999), por fim, sugeriram que a habilidade preditiva em escalas de tempo sazonais está ligada à evolução lenta das condições de contorno do sistema climático, como temperatura da superfície do mar, cobertura de neve, umidade do solo, gelo marinho e assim por diante.

A identificação de teleconexões climáticas globais estatisticamente significativas associadas ao ENSO resultou em parâmetros correlacionados com outros fatores climáticos de variação lenta, sendo usados como preditores em modelos de previsão empíricos/estatísticos para anomalias de temperatura e precipitação de superfície em grande escala em muitos países em todo o mundo (BARNSTON, 1994; DROSDOWSKY E CHAMBERS, 2001; RAJEEVAN *et al.*, 2007; PAI *et al.*, 2017).

Os modelos estatísticos forneceram uma referência para avaliar a habilidade dos modelos dinâmicos globais de circulação geral (GCMs) de última geração, agora comumente usados para previsão climática sazonal.

Já as primeiras ações para uma previsão climática sazonal com base em modelos dinâmicos foram dadas por Norman Phillips em 1956, quando desenvolveu um modelo matemático para simular padrões de circulação troposférica mensal e sazonal. Em seguida, houve esforços direcionados por vários grupos de pesquisa para desenvolver modelos de circulação geral.

A previsão da variabilidade do ENSO com um modelo dinâmico simples acoplado oceano-atmosfera foi demonstrada pela primeira vez por ZEBIAK e CANE (1987). O trabalho subsequente apoiado pelo estabelecimento de um projeto internacional de dez anos (1985-1994) de Oceanos Tropicais e Atmosfera Global (TOGA) e a implementação do sistema de observação oceânica no Pacífico equatorial levaram ao desenvolvimento dos sofisticados sistemas operacionais de previsão ENSO de hoje (ANDERSON, D.T *et al.*, 1998; MCPHADEN *et al.*, 2010).

À vista disso, houve uma melhoria notável na habilidade preditiva de modelos dinâmicos durante as últimas décadas, principalmente devido aos avanços na estimativa inicial das condições oceânicas e atmosféricas, bem como avanços na física do modelo e nas capacidades de computação (BAUER *et al.*, 2015). Tal melhoria se dá pelo aumento de interesse e demanda por serviços climáticos desencadeados pelo forte evento de El Niño de 1997/1998 sendo o mais intenso do século XX.

O El Niño de 97/98 forneceu um exemplo dramático dos efeitos das variações climáticas em curto prazo na sociedade e o valor potencial de prevê-las. O período de 1997 a 1998 também coincidiu com a campanha bem-sucedida de observações oceânicas da matriz ancorada do Oceano de Atmosfera Tropical (TAO) em todo o Pacífico equatorial e o desenvolvimento de vários modelos de previsão oceânica usando dados do TAO.

Por consequência à resposta positiva dos Fóruns Regionais de Perspectivas Climáticas (RCOFs), que foram estabelecidas pela primeira vez em 1996 em uma reunião realizada em Victoria Falls ao evento El Niño de 1997/1998, deu um impulso para o desenvolvimento do conceito de RCOFs. O El Niño de 1997/1998, no entanto, não reproduziu os padrões clássicos de anomalias climáticas globais, como as observadas no

evento de 1982/1983 (o segundo evento mais forte do século XX). Essa discrepância colocou em questão a noção de que diferentes eventos do El Niño podem levar a impactos semelhantes no clima global.

Essas observações no padrão do El Niño forneceram suporte para a visão de que o impacto da temperatura da superfície do mar (TSM) no clima diário não é determinístico, pois mesmo uma pequena incerteza na condição inicial pode levar a incerteza na previsão sazonal além de um período de uma semana ou mais (LORENZ, 1969). Foi justamente a necessidade de comunicar a incerteza na previsão que resultou na introdução do conceito de abordagens probabilísticas e de conjunto para previsão meteorológica e sazonal.

Atualmente, os centros de previsão operacionais usam modelos dinâmicos de circulação geral global (GCMs) acoplados ao oceano-atmosfera de última geração para gerar previsões sazonais. Embora os GCMs atmosféricos (AGCMs) tenham sido os primeiros a aparecer em cena, os GCMs acoplados (CGCMs) ganharam preferência sobre os AGCMs porque se espera que representem melhor as interações entre os diferentes componentes do sistema climático atmosfera, oceano, criosfera e assim por diante (WMO, 2019).

Desde 2006, como parte do desenvolvimento de uma infraestrutura para seu Sistema Global de Processamento de Dados e Previsão (GDPFS), a WMO designou centros de previsão com a responsabilidade obrigatória de gerar e entregar previsões sazonais (com cobertura global), incluindo informações de verificação associadas. Existem atualmente 13 desses chamados Centros de Produção Global para Previsões de Longo Prazo. Em 2009, a OMM endossou formalmente o Lead Center for Long-Range Forecast Multi-Model Ensemble, organizado conjuntamente pela Korea Meteorological Agency (KMA) e pelos National Centers for Environmental Prediction (NCEP). Isso facilitou o acesso mundial aos dados de previsões sazonais baseadas em conjuntos de vários modelos.

2.2 Componentes da Variabilidade Climática

A variabilidade nos componentes do sistema terrestre, por exemplo, o oceano e a atmosfera ocorrem em todas as escalas de tempo e em diferentes escalas espaciais. As variações temporais ocorrem em escalas de segundos a séculos (turbulência atmosférica)

e são organizadas em escalas espaciais de centímetros para ondas planetárias atmosféricas de mais de milhares de quilômetros (WILLIAMS *et al.*, 2017).

Em escalas de tempo meteorológicas, ciclones nos trópicos e sistemas de escala sinótica nos extratropicos dominam a variabilidade atmosférica. A estrutura espacial da variabilidade em escalas de tempo semanais pode ser discernida como o padrão Pacífico Norte-Americano (PNA) (WALLACE E GUZTLER, 1981) ou a Oscilação do Atlântico Norte/Oscilação do Ártico (BARNSTON E LIVEZEY, 1987; THOMPSON E WALLACE, 1998).

Já a interação de escala entre os modos de variabilidade atmosférica, por exemplo, o padrão PNA e a variabilidade sinótica, altera a trajetória das tempestades sinóticas extratropicais, o que, por sua vez, ajuda a manter a primeira (PINTO *et al.*, 2011). É reconhecido que a variabilidade atmosférica em escalas de tempo meteorológicas não pode ser prevista além de um lead time de 15 dias (LORENZ, 1969; HOSKINS, 2013).

Para o contexto das previsões de longo prazo e do potencial para realizá-las habilidosamente, temos que os modos de variabilidade em escalas de tempo subsazonais e sazonais que desempenham um papel crítico. Além disso, à medida que a escala temporal de variabilidade aumenta, os modos preferidos de variabilidade envolvem interações entre vários componentes do sistema terrestre, por exemplo, oceano, terra e atmosfera.

Em escalas de tempo subsazonais e escalas espaciais globais, o modo dominante de variabilidade atmosférica é a Oscilação Madden-Julian (MJO), que se propaga ao longo da zona equatorial em escalas de tempo de 30 a 60 dias (MADDEN E JULIAN, 1971; ZHANG, 2005). A presença da MJO modula a variabilidade atmosférica em diferentes partes do globo, incluindo a frequência de furacões no Atlântico tropical e precipitação sobre o oeste dos Estados Unidos, América do Sul, África, Continente Marítimo e outros locais (por exemplo, ZHOU *et al.*, 2012).

Já em escalas de tempo sazonais a interanuais, o modo de variabilidade mais importante é o El Niño-Oscilação Sul (ENSO) e envolve a interação ar-mar acoplada no Pacífico tropical equatorial. As influências locais do ENSO incluem variações na Temperatura da superfície do mar (TSM) no Pacífico equatorial central e oriental. Variações nas TSM, por sua vez, modulam a localização da convecção profunda sobre áreas adjacentes. Mudanças na vazão de nível superior resultam em mudanças na

circulação de nível superior tropical que, através de ondas de Rossby que se propagam meridionalmente, alteram a variabilidade atmosférica a jusante em regiões extratropicais (HOREL E WALLACE, 1981; SARDESHMUKH E HOSKINS, 1988; TRENBERTH et al., 1998).

As influências remotas do ENOS, juntamente com a inércia térmica oceânica, ou seja, o fato de a TSM variar em escala de tempo mais longa fornece o potencial para previsões sazonais hábeis. De fato, essas ligações foram o impulso para o início do programa TOGA e o aprimoramento do sistema de observação oceânica no Pacífico tropical equatorial, seguido pelo desenvolvimento inicial de sistemas operacionais de previsão sazonal acoplados em meados da década de 1990 (apud MCPHADEN *et al.*, 2010).

2.3 Mudanças Climáticas

Segundo o Painel Intergovernamental sobre Mudanças Climáticas (IPCC) 2018, estima-se que as atividades humanas tenham causado um aquecimento global de 1,0°C acima dos níveis pré-industriais e que esse aumento pode atingir 1,5°C entre 2030 e 2052 caso continue no ritmo atual. O aquecimento causado por emissões antrópicas desde o período pré-industrial até o presente persistirá por séculos e milênios, e continuará causando mudanças em longo prazo no sistema climático, como aumento dos níveis dos oceanos, com impactos associados, mas é improvável que apenas essas emissões isoladamente causarão um aquecimento global de 1,5°C.

Modelos climáticos projetam diferenças robustas nas características climáticas regionais entre os dias atuais e o aquecimento global de 1,5°C, e entre 1,5°C e 2°C. Essas diferenças incluem aumentos: em temperatura média na maioria das regiões terrestres e oceânicas, nos extremos de calor na maioria das regiões habitadas, na ocorrência de chuva intensa em diversas regiões e na probabilidade de seca e déficits de chuva em algumas regiões (IPCC, 2018).

As distintas modificações e consequências provocadas pela ação humana no sistema climático estão sendo observadas constantemente, e as causas mais discutidas são as mudanças nas concentrações de gases de efeito estufa (GEEs), no uso da terra, nas quantidades de aerossóis na atmosfera, etc. Essas modificações têm impactos no clima, tanto regionalmente quanto globalmente (IPCC, 2007; IPCC, 2013).

Devido à vulnerabilidade às mudanças climáticas, algumas regiões necessitam de maior busca por conhecimento e estudos mais direcionados acerca do seu clima, como o Nordeste do Brasil e a Amazônia, sujeitas a alterações na distribuição de eventos extremos, veranicos, disposição espacial de chuvas, etc., com diversos sistemas contribuindo para a variabilidade climática e possivelmente a alterações climáticas naturais e antrópicas (RIBEIRO *et al.*, 1996; OYAMA e NOBRE, 2003; PBMC, 2012; KAYANO e ANDREOLI, 2016).

Os efeitos de desertificação, por exemplo, pode ser encontrado no semiárido brasileiro, sendo este o espaço geográfico mais vulnerável, compreendendo 11,53% do território nacional, predominantemente na região nordeste (56,46% - INSA, 2012), o regime de chuvas irregularmente distribuídas no espaço e no tempo propiciam este cenário, outrossim, há precipitações em torno de 800 mm ao ano, concentradas em períodos de três a cinco meses e elevadas médias anuais de temperatura (27 °C) e evapotranspiração potencial (2.000 mm/ano), apresentando balanço hídrico negativo em grande parte do ano, com solo ralo e bioma Caatinga (LIMA *et al.*, 2011).

A vida da caatinga se encontra entre os mais suscetíveis em um cenário de mudanças na cobertura vegetal da porção tropical da América do Sul (OYAMA e NOBRE, 2003), pois o aumento da temperatura, associado a atividades antrópicas de remoção da vegetação de Caatinga, propicia a ocorrência de aridização e desertificação.

Dentre as projeções climáticas, um estudo de MARENGO (2009) mostra que para o século 21, os Modelos de Circulação Geral (MCGs) utilizados no AR4, apontam aquecimento em todo o Brasil. No NEB, os MCGs divergem nos resultados projetados para a precipitação, entre aumento e diminuição, mas a média dos modelos indica maior probabilidade de redução de chuvas - possível decorrência do aquecimento global; assim citado também: “Para o Nordeste, a tendência é de redução de chuvas acompanhada de aumento da temperatura para finais do século XXI” (MARENGO e VALVERDE, 2007).

Neste cenário brasileiro, as projeções do PBMC (Painel Brasileiro de Mudanças Climáticas) para o NEB são de decréscimo entre 10% e 20% da precipitação e aumento de 0,5 a 1 °C da temperatura do ar durante as próximas três décadas (até 2040), com aumento gradual de temperatura de 1,5 a 2,5 °C e diminuição entre 25% e 35% nos padrões de chuva no período de 2041-2070, tais mudanças e alterações podem

desencadear o processo de desertificação da caatinga (PBMC, 2012) como já citado anteriormente.

Já o relatório PMBC 2014, observou uma marcante concentração dos registros das mudanças climáticas abruptas na Região Nordeste do Brasil e no oceano adjacente, identificou, por exemplo, alguns fatores que contribuem para tal concentração, como a alta amplitude do sinal das mudanças climáticas abruptas nesta região do continente e oceano, em função do impacto da ZCIT (Zona de convergência intertropical) no clima regional e de sua relação com processos de degelo em latitudes elevadas do hemisfério norte associados a tais alterações.

Ainda sobre os problemas climáticos no Nordeste brasileiro, durante séculos, as secas nesta região causaram vários impactos ambientais, sociopolíticos e econômicos. Dentre os impactos ambientais, podem-se citar prejuízos às plantas, aos animais e aos peixes, alteração na qualidade da água e do ar, aumentando a quantidade de poeira e de poluentes, perda do solo (por erosão, salinização, alcalinização), além de alterações na paisagem (CGEE e ANA, 2012).

Na área dos impactos sociopolíticos podemos incluir problemas de saúde (como, por exemplo, associados ao uso de águas provenientes de açudes ou poços, com qualidade inferior), impacto na vida da população afetada (apud CGEE e ANA, 2012), mortes humanas por fome, desnutrição e doenças e migração de pessoas (MARENCO *et al.*, 2017). Os danos econômicos, por sua vez, podem ser representados por perdas na produção agrícola, na produção de carne de laticínios, na produção de madeira, nos lucros com recreação, além de uma desorganização das atividades econômicas existentes (apud CGEE e ANA, 2012; apud MARENCO *et al.*, 2017).

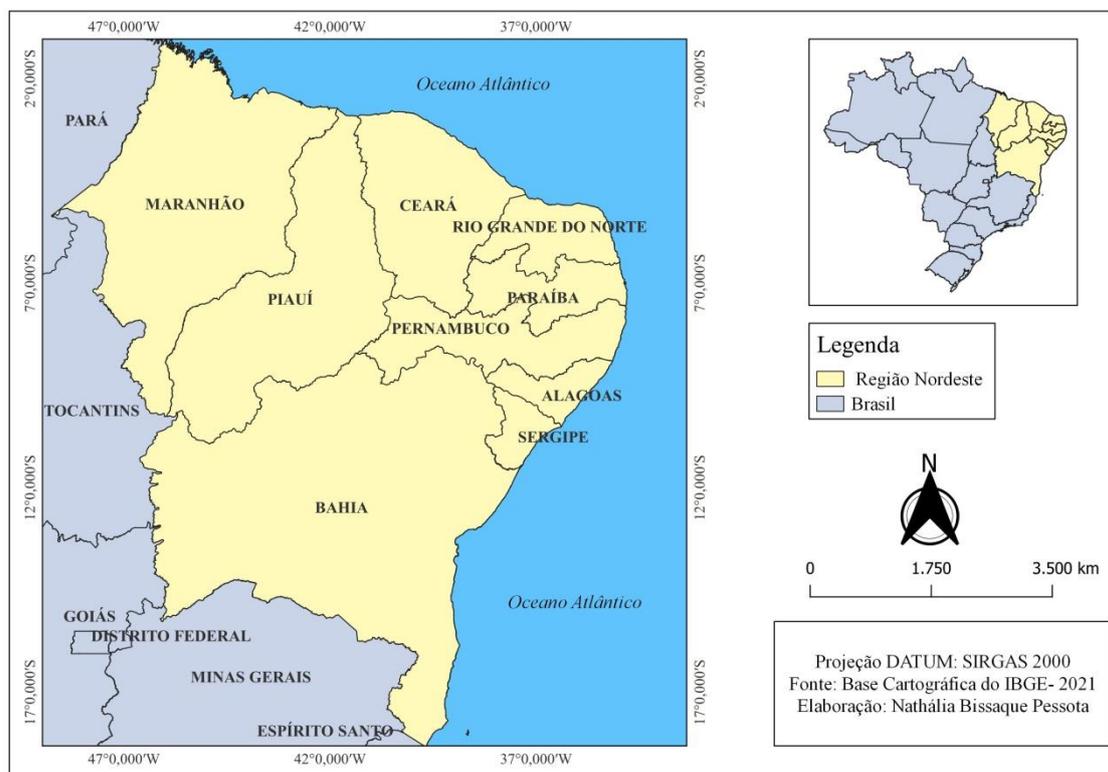
Desta maneira, sobre o Nordeste Brasileiro, que é diretamente assolado com períodos de seca, projeções para o clima futuro são fundamentais para estratégias de adaptação e combate à vulnerabilidade, sendo esta região o foco do presente estudo.

2.4 Nordeste brasileiro

O Nordeste Brasileiro (NEB) possui uma grande extensão territorial, aproximadamente 1.600.000 km², seguido de um regime pluviométrico irregular. A região do NEB ocupa a posição norte-oriental do país, entre 1° e 18°30' de latitude Sul e 34°30' e 40°20' de longitude Oeste de Greenwich, abrangendo nove estados: Maranhão,

Piauí, Ceará, Rio Grande do Norte, Paraíba, Pernambuco, Alagoas, Sergipe e Bahia (CIRILO *et al.*, 2007).

Figura 1 - Unidades federativas da região Nordeste



Fonte: Autora, 2022.

Segundo ARAÚJO COSTA (2014) a porção semiárida do Nordeste do Brasil compreende uma área aproximada de 936.993 km² e atinge na média mais de 50% da área total; esta porção conta com históricos de secas desde o século XVI, atingindo a sobrevivência de boa parte dos moradores da região.

As características climáticas do NEB representadas pela variabilidade das chuvas e sazonalidade da precipitação condiciona uma relação direta com o comportamento fluvial (ZANELLA, 2014). O NEB possui registros pluviométricos entre (800mm-1.200mm) com períodos prolongados de estiagens e secas extremas, essa condição traz grandes impactos para a população que reside nessa localidade, além de problemas socioeconômicos (DOS SANTOS *et al.* 2017; DE OLIVEIRA, *et al.* 2018; DA ROCHA JÚNIOR *et al.*, 2019; 2020).

Podemos identificar três climas diferentes distribuídos ao longo da região nordeste, no litoral, sul da Bahia e no centro do Maranhão o clima predominante é o tropical, sendo caracterizado pela presença de uma estação chuvosa bem definida, já o clima equatorial úmido encontra-se em uma área no oeste do Maranhão, apresentando altas temperaturas e grande pluviosidade. Por fim, tem-se o clima semiárido, característico da região central do Nordeste (sertão nordestino), no qual a precipitação é baixa e irregular, gerando períodos de estiagem (COSTA *et al.*, 2020).

Existe uma região no Nordeste que é mais regularmente afetada pelas secas, conhecida como Polígono das Secas, possuindo ainda uma sub-região semiárida conhecida como Sertão, que abrange uma área de cerca de 912.200 km² (MARENGO e BERNASCONI, 2015), caracterizada pela presença de rios intermitentes e de um solo pedregoso e pobre (apud CGEE e ANA, 2012).

A presença da região semiárida foi explicada por Moura e Shukla (1981) por alguns fatores, primeiro, está localizada na vizinhança de uma inversão de ventos alísios e, em razão de sua geografia, uma parte de sua área encontra-se na zona de influência permanente da alta subtropical do Atlântico Sul, segundo o albedo diferencial e os efeitos locais da topografia também influenciam nos padrões climáticos. Outros elementos que podem contribuir é a existência na região de solos rasos, que possuem pouca capacidade de armazenamento hídrico, e de altas taxas de evaporação, em combinação com o fato das precipitações serem concentradas em uma época do ano (apud CGEE e ANA, 2012).

Igualmente, os impactos causados por secas intensas configuram-se, portanto como um dos principais desastres climáticos dos trópicos em função das grandes perdas econômicas e problemas sociais que causam (HASTENRATH *et al.*, 1984; HASTENRATH, 1990). Apenas em 1958, por exemplo, aproximadamente 10 milhões de pessoas abandonaram suas residências em função da seca, enquanto a seca de 1979-1983 custou cerca de 7,8 bilhões de dólares para o governo (apud CGEE e ANA, 2012; apud MARENGO *et al.*, 2017).

As causas apontadas para as secas remontam ao clima predominantemente semiárido, com alta variabilidade interanual e espacial da precipitação, chegando a menos de 400 mm por ano em algumas áreas (KOUSKY, 1979), e à grande vulnerabilidade da região, em especial por parte da população mais carente. Apesar do investimento em medidas mitigatórias de infraestrutura, a população, especialmente os mais pobres, ainda

sofre com as consequências desse fenômeno natural, lidando, por exemplo, com o risco à segurança alimentar, hídrica e energética (ANDERSON *et al.*, 2015).

A dinâmica espaço-temporal das chuvas no Nordeste é complexa e seu entendimento científico, assim como de mecanismos de teleconexões climáticas associadas, remonta da década de 1970. Foram encontradas relações entre o desastre natural e alguns mecanismos climáticos, tais como a temperatura da superfície do mar (TSM) no Oceano Atlântico (apud HASTENRATH, 1990; apud HASTENRATH *et al.*, 1984; HASTENRATH e HELLER, 1977), a posição da Zona de Convergência Intertropical (ZCIT) (apud HASTENRATH, 1990; apud MOURA e SHUKLA, 1981; BRAHMANANDA RAO *et al.*, 1993), a pressão ao nível do mar nos Oceanos Atlântico e Pacífico tropical (apud HASTENRATH e HELLER, 1977; HASTENRATH, 1978), os ventos alísios (NAMIAS, 1972; KOUSKY, 1980), o fenômeno El Niño (apud MARENGO *et al.*, 2017) e as frentes frias (apud KOUSKY, 1979).

Estudos prévios investigaram como a distribuição das chuvas ocorre e quais os mecanismos associados aos padrões anômalos (BONAVITA *et al.*, 2016; GELARO *et al.*, 2017; ESCOBAR, 2019; KELLEY *et al.*, 2020), a exemplo do El Niño-Oscilação Sul que provocam impactos na qualidade do regime de chuva dependendo de sua fase (CAVALCANTI 2012; HASTENRATH, 2012; MARENGO *et al.*, 2017; SOUZA *et al.*, 2018; SILVA *et al.*, 2020). Nesse sentido, estudos de modelagem numérica podem auxiliar tanto a diagnosticar quanto a prever os impactos das variabilidades climáticas em determinada região.

2.5 El Niño-Oscilação Sul e os efeitos no Nordeste brasileiro

Os termos El Niño e La Niña provêm do espanhol e referem-se à presença de águas quentes ou frias, respectivamente, que, todos os anos, aparecem na costa norte do Equador e Peru na época de Natal. Os pescadores desses países chamaram a esta presença de águas mais quentes de Corriente de El Niño em referência ao Niño Jesus ou Menino Jesus (DE ARAÚJO COSTA, 2014).

El Niño-Oscilação Sul (ENOS) é um modo natural do sistema acoplado oceano-atmosfera na região do Pacífico Tropical, caracterizado por flutuações irregulares de 2 a 7 anos, aproximadamente e entre as fases quentes (El Niño) e a fria (La Niña). Em tese, o ENOS compreende o sinal climático mais intenso na escala interanual com implicações

significativas na circulação atmosférica tropical, afetando os ecossistemas, a agricultura, o abastecimento de água doce, a frequência e intensidade de eventos climáticos severos como furacões em todo o mundo (ALEXANDER *et al.*, 2002).

O aquecimento do oceano e o conseqüente enfraquecimento dos ventos geram mudanças na circulação atmosférica nos níveis baixos e altos, determinando alterações nos padrões de transporte de umidade e, portanto, variações na distribuição das chuvas em regiões tropicais e de latitudes médias e altas; observa-se também, em algumas regiões do globo, o aumento ou queda de temperatura (FUNCEME, 2009).

O ENOS opera nos trópicos através de variações nas células de Walker e Hadley (ZHOU e LAU, 2001), e nos extratropicais por meio de onda de Rossby (NOGUÉS-PAEGLE *et al.*, 2002). O El Niño causa seca na faixa equatorial da América do Sul, incluindo o nordeste brasileiro e que são associadas a uma célula de Walker deslocada para leste cujo ramo descendente se posiciona nas longitudes desta faixa (RAO e HADA, 1990).

No Nordeste Brasileiro, as secas não correspondem à mera estiagem. A rigor, elas constituem um complexo fenômeno socioeconômico, no qual as oscilações de volume e a distribuição temporal das precipitações pluviométricas redundam em desorganização da atividade econômica. É possível mencionar que existe uma relação direta de causa e efeito entre o fenômeno El Niño e as secas no Nordeste do Brasil, pelo menos no prolongamento do período seco além do normal, uma vez que, a mudança anômala na circulação da atmosfera superior e a conseqüente alteração na dinâmica dos centros de altas e baixas pressões bem como na modificação das células do ar atmosférico constituem, mecanismos que explicam a ocorrência das grandes secas no Nordeste do Brasil (DE ARAÚJO COSTA, 2014).

Esta relação está claramente determinada e exposta na Tabela 1 onde se constata a coincidência, não fortuita, dos dois eventos. Nota-se, sobretudo, a coincidência dos fatos relativos aos eventos das grandes e devastadoras secas de 1877, 1982/3 e de 1997.

Tabela 1 - Relação entre eventos ENOS e Secas no Nordeste do Brasil.

FENÔMENO	Anos de Ocorrência					
SECAS	1877	1914	1932	1945	1948	1953
	1965	1970	1982	1993	1997	
ENOS	1877	1914	1932	1945	1948	1953
	1965	1970	1982	1993	1997	

Fonte: DE ARAÚJO COSTA, 2014.

Os atuais modelos do sistema climático global dispõem de modelos oceânicos e, portanto, há a necessidade de avaliar o quanto estes modelos acoplados do sistema climático reproduzem as características desses diferentes tipos de ENSO, assim como os seus impactos na distribuição global da precipitação (VIEGAS, 2019).

Os modelos climáticos, embora tenham algumas limitações, podem contribuir para complementar as informações do sistema climático acoplado juntamente com os registros das observações, igualmente, fornecerá subsídios para avaliar os aspectos do acoplamento oceano-atmosfera que pode levar ao entendimento das características específicas dos modos de variabilidade do ENSO. Simulações com alterações nas forçantes oceânicas juntamente com condições não-forçadas, são úteis para entender a gênese dos diferentes regimes de atividade do ENSO (apud VIEGAS, 2019).

2.6 Modelos Empíricos

Os modelos de base empírica que são os modelos estatísticos (WU *et al.*, 1994; HASTENRATH *et al.*, 2009), são construídos através de observações do clima passado. A utilização de ferramentas estatísticas no prognóstico climático, em acréscimo às previsões fornecidas pelos modelos dinâmicos, mostra-se como uma possibilidade bastante promissora, especialmente em regiões geográficas onde os recursos computacionais necessários para a implementação de modelos dinâmicos não se encontram disponíveis ou os modelos dinâmicos disponíveis ainda apresentam habilidades insuficientes.

Os modelos empíricos apresentam características que estabelecem relações empíricas dentro de um conjunto de dados experimentais conhecidas e se ajustam a um conjunto de equações simultâneas sobre as séries do passado de modo completamente experimental, apresentando atributos como, eficiência em predições, modelos

essencialmente descritivos, relacionamento entre variáveis, necessitam de um número reduzido de variáveis, usam de modelos matemáticos simples e são sempre dependentes do tamanho da série de observações;

Afim de obter informações a respeito de um grupo de variáveis ou um conjunto total dos dados de uma região, é usual recorrer-se à análise multivariada. Estas técnicas estatísticas são utilizadas para reduzir ao máximo o número de variáveis envolvidas em um problema com uma pequena perda de informações, tendo como principais objetivos a: - Redução da dimensão de interpretação de uma matriz de dados; - Investigação do comportamento espacial e temporal das variáveis consideradas; - Obtenção de grupos homogêneos das variáveis. Assim sendo, existem várias técnicas de manejo de dados muito úteis na Análise Multivariada como, por exemplo, a Regressão Linear Múltipla (RLM), a Análise de Componentes Principais (ACP) e a Análise de Correlação Canônica (ACC) que será utilizada neste trabalho, entre outras (DA ROCHA JÚNIOR *et al.*, 2021).

2.7 Análise de Correlações Canônicas (ACC)

A análise de correlações canônicas (ACC) é um método estatístico multivariado e que consiste em associar índices a cada um dos conjuntos de dados (X: variável explicativa e Y: resposta), definidos como combinações lineares dos valores em cada um dos conjuntos (Empirical Orthogonal Function - EOF), de forma a maximizar a correlação entre os dois índices, igualmente, retém ao máximo a informação contida nas variáveis originais.

O método canônico pode ser visto como a medida da existência e a intensidade da associação entre dois grupos de variáveis ou caracteres de importância; existindo duas ou mais variáveis dependentes (DA SILVA, 2007).

A introdução da ACC aconteceu em 1936 por Hotelling, sendo muito pouco explorada no passado. Dentro dos campos meteorológicos, GLAHN (1968) foi o primeiro a desbravar esta aplicação. Mais detalhes sobre a ACC é fornecido em BARNETT e PREISENDORFER (1987), GRAHAM *et al.* (1987a, 1987b), BARNSTON e ROPELEWSKI (1992), BARNSTON (1994), e suas referências. Breves tratamentos matemáticos são encontrados no apêndice do BARNETT e PREISENDORFER (1987) e na seção 3b de GRAHAM *et al.* (1987a).

A ACC foi estimada como medida de associação conforme considerações gerais de CRUZ e CARNEIRO (2003) e refere-se às correlações lineares entre variáveis de tal modo que as combinações sejam máximas.

A ACC está no topo da hierarquia de modelagem de regressão (BARNETT e PREISENDORFER, 1987), devido aos campos do preditor e do preditando conterem um grande número de variáveis altamente correlacionadas e poucas observações, determinando a melhor combinação linear de dois conjuntos de dados (preditor, por exemplo, TSM, e o preditando, precipitação observada).

Por outro lado, a correlação canônica é usada também com eficiência na descrição de dados, verificação de modelos numéricos e construção de modelos estatísticos de previsão, proporcionando o conhecimento de quais configurações tendem a ocorrer simultaneamente entre dois ou mais campos distintos e qual o grau de conexão entre eles.

Como uma ferramenta de previsão, o ACC tem várias vantagens sobre outras técnicas convencionais, tais como a regressão linear múltipla. Como um modelo linear, no entanto, ACC não explica completamente as relações não lineares.

Neste trabalho, quando da construção do modelo empírico de previsão, ela será utilizada para identificar os campos de precipitação (X) mais altamente correlacionados com padrões de anomalia de TSM (Y). Ao ser usado como ferramenta de correção do *downscaling* dinâmico, a variável explicativa passa a ser a precipitação simulada pelo modelo dinâmico, sendo que a resposta continua a ser a precipitação observada.

2.8 Modelos dinâmicos

Os modelos dinâmicos são modelos computacionais de previsão numérica desenvolvidos para simular/prever o comportamento da atmosfera. Existe um sistema complexo de equações matemáticas nas formas mais complexas e completas, baseadas em leis físicas de modo a prever o estado futuro da atmosfera partindo de condições iniciais específicas e que são resolvidas por esses modelos dinâmicos e termodinâmicos. Ademais, processos físicos, como a radiação, nuvens, precipitação e trocas à superfície são representadas no modelo utilizando esquemas de parametrizações.

No modelo dinâmico temos a divisão do planeta em várias camadas verticais que representam níveis da atmosfera, e divide a superfície do planeta numa malha de caixas

horizontais separadas por linhas similares às linhas de latitude e longitude. Com isso o planeta é coberto por uma malha tri-dimensional.

Os modelos dinâmicos possuem algumas vantagens em relação aos modelos empíricos, uma delas trata-se da representação de processos físicos, como parametrização de convecção e radiação, com o objetivo de melhorar a qualidade das previsões. Outro benefício dinâmico é o fato de que tais modelos assumem a não estacionariedade do clima, enquanto que a maioria dos modelos empíricos assume a estacionariedade do clima, vale-se expor que os modelos dinâmicos são computacionalmente mais caros em relação aos modelos empíricos dificultando entre partes, sua utilização.

A comunidade científica têm se dedicado as melhorias dos processos físicos nos modelos dinâmicos para uma satisfatória representação das condições climáticas presentes e futuras.

Para realizar uma previsão, os modelos partem de um conjunto de condições iniciais, sendo suas equações integradas no tempo para prever o estado da atmosfera num tempo futuro. Podem ocorrer pequenos erros nas condições iniciais e que se amplificam à medida que a simulação avança no tempo, de modo que a diferença entre as condições atmosféricas prevista e as condições reais da atmosfera aumenta ao longo da previsão, isto torna inviáveis previsões de tempo com mais do que duas semanas de antecedência, no entanto, as previsões climáticas seguem outro princípio: estatísticas de conjuntos (ensembles) de simulações forçadas por condições de contorno (como a TSM).

Do passado para o presente e para o futuro previsível, secas e inundações acontecem com frequência (ROSER e ORTIZ-OSPINA, 2016). A previsão de precipitação como o principal componente do sistema climático (ciclo da água), pode ser muito eficaz na redução dos potenciais danos dos desastres naturais, embora possa ser essencial na construção de resiliência ao clima (recursos hídricos extremos, planejamento e gestão).

Durante a última década, respondendo a esta necessidade, numerosos modelos dinâmicos de previsão de precipitação (AL ZAWAD e AKSAKAL, 2010; FENTA MEKONNEN e DISSE, 2018; HATTERMANN *et al.*, 2017; PENG *et al.*, 2018) foram desenvolvidos e explorados. Esses modelos são geralmente classificados na categoria de Modelos de Circulação Global (GCMs). Entre os diferentes GCMs existentes, o modelo North American Multi-Model Ensemble (NMME) é um modelo de precipitação sazonal

eficaz para modelos de acoplamento de previsão de precipitação dos EUA e centros canadenses de modelagem climática, e é capaz de fornecer informações sazonais de previsão de precipitação desde 2007 com facilidade de acesso aos dados (BECKER *et al.*, 2020; ROY *et al.*, 2020; SLATER *et al.*, 2019). Desde então, encontrar a relação entre os dados observados e os dados previstos inspiraram muitos pesquisadores em todo o mundo a avaliar as habilidades de previsão do modelo NMME.

O North American Multi-Model Ensemble (NMME) foi desenvolvido para melhorar a habilidade das previsões meteorológicas sazonais (BECKER *et al.*, 2013; KIRTMAN *et al.*, 2014). Oferece oportunidades valiosas para caracterizar a incerteza do modelo e das condições iniciais usando um grande número de modelos contribuintes, cada um consistindo em vários membros do conjunto. O projeto NMME está sendo utilizado operacionalmente por, por exemplo, o CPC (Climate Prediction Center) e o IRI (International Research Institute for Climate and Society). Além disso, vários estudos avaliaram o desempenho de NMME no contexto de previsões ENSO (por exemplo, TIPPETT *et al.*, 2019; LANDMAN *et al.*, 2019), bem como, previsões mensais europeias de temperatura e precipitação (RODRIGUES *et al.*, 2019) e previsões climáticas extremas (SLATER *et al.*, 2019). Sendo todas as saídas do modelo uma resolução de $1^\circ \times 1^\circ$ e prazos de entrega previstos de pelo menos até 9 meses.

Os modelos de previsão numérica são classificados segundo a sua escala espacial, sendo o modelo global com a resolução da ordem de várias dezenas a poucas centenas de quilômetros, visa identificar o comportamento geral da atmosfera sobre uma área extensa; estes modelos são apenas capazes de identificar fenômenos meteorológicos de grande escala (sinóticos); já o modelo regional (ou local) possui resolução espacial típica de quilômetros a dezenas de quilômetros, visa identificar com maior detalhe o comportamento da atmosfera sobre uma região específica, sendo apropriados para identificar fenômenos meteorológicos de menor escala (ditos de mesoescala), como brisas, interação entre o escoamento atmosférico, topografia, etc.

Os modelos globais se destinam a descrever movimentos atmosféricos sobre o planeta como um todo, também denominados Modelo de Circulação Geral Atmosférico (MCGA) ou Modelo de Circulação Geral (MCG) e podem ser acoplados a modelos oceânicos e/ou a modelos de outros componentes do clima.

Os MCGs podem ser configurados para previsão de tempo ou para estudos climáticos, quando da previsão de tempo, o modelo é executado por um tempo físico de alguns dias (entre uma e duas semanas) e tem em vista representar a formação e a evolução de sistemas de tempo de grande escala da forma mais realista possível. Já para previsão climática, o modelo não se interessa em sistemas de tempo individuais, mas nas propriedades estatísticas da circulação atmosférica em escalas de tempo de meses ou mesmo anos.

Como variáveis de saída, os modelos globais fornecem temperatura do ar, velocidade do vento em várias direções, cobertura de nuvens, precipitação, umidade do solo, cobertura de neve, radiação solar, pressão e temperatura na superfície do mar, entre outras. A baixa resolução desses modelos deve-se ao poder computacional exigido para a execução dos mesmos, pois quanto maior a resolução espacial requerida, maior será o tempo de computação necessário.

Já os modelos locais ou regionais, são aqueles cujo espaçamento de grade é menor do que aquele usado em modelos globais, permitindo assim a representação de fenômenos de mesoescala. Normalmente, tais modelos se aplicam a estudos ou previsões de tempo em escala regional e local. Como sua grade não cobre toda a extensão da superfície terrestre (como os modelos globais), mas somente a atmosfera sobre uma dada área, são também chamados de modelos de área limitada. Esses modelos permitem a representação de fenômenos que dificilmente são simulados em modelos globais, como a evolução de sistemas de tempo de mesoescala, a influência da topografia, etc. Isso se dá graças à melhor resolução dos modelos de mesoescala, cujo espaçamento de grade varia entre menos de uma a algumas dezenas de quilômetros.

Do ponto de vista de suas aplicações, recentemente os modelos de área limitada têm não somente servido para fins de previsão de tempo (como os modelos ETA, RAMS, MM5, RSM, etc., em diversos centros de meteorologia do Brasil e do exterior), mas também têm encontrado uso em estudos climáticos, através da técnica conhecida como *downscaling* dinâmico.

2.9 Downscaling

Os MCGs conseguem representar, como ferramenta de previsão sazonal, e de maneira significativa os padrões de grande escala, porém os mesmos modelos apresentam

baixa resolução (resolução espacial da ordem de 100 a 40 200 km), lhes faltando, por exemplo, antever prognósticos mais detalhados da distribuição espacial da chuva na escala intrasazonal (controlada por fatores com escala tipicamente bem menor), além da própria variabilidade temporal dessa distribuição de precipitação.

Portanto, como forma de solucionar o problema da diferença entre a escala para a qual são realizadas as previsões por MCGs e a escala da região onde se deseja empregá-las, tem-se usado técnicas de transferência da informação meteorológica para as escalas menores, as chamadas, técnicas de *downscaling*, desenvolvidas pela necessidade de se ter uma informação mais detalhada no tempo e no espaço dos produtos de previsão numérica de tempo e clima.

Resumidamente, o *downscaling* trata do uso dos resultados de uma modelagem de grande escala para alimentar um modelo de menor escala, seja um modelo numérico regional de área limitada, com uma resolução da ordem de dezenas de quilômetros (DICKINSON *et al.*, 1989), seja um modelo empírico.

As técnicas de *downscaling* podem ser classificadas em duas categorias, sendo *downscaling* dinâmico a que envolve o uso de modelos numéricos de escalas global e regional, e requer informação climática (de superfície) detalhada, assim como uma alta disponibilidade computacional. Por outro lado, as empíricas empregam métodos estatísticos, sendo que os mais empregados são os métodos de regressão (lineares e não lineares), geradores de tempo (análises de componentes principais, análises de correlação canônica, redes neurais artificiais) e os estocásticos (teoria fuzzy – conjuntos nebulosos, algoritmos genéticos, etc).

No *downscaling* dinâmico, usa-se um modelo meteorológico de resolução mais alto (regional), com espaçamento de grade da ordem de algumas dezenas de quilômetros, alimentado nas fronteiras pelas condições produzidas pelo modelo global (ou até por dados observados). Por representar com maior detalhe os processos que agem regionalmente, acredita-se que os modelos regionais podem produzir previsões de tempo e clima com maior precisão.

Vale-se dizer que há um custo computacional necessário para executar as simulações históricas das previsões, a existência de uma boa rede de observação é crucial para a validação dos dados a partir de modelos de alta resolução no *downscaling* dinâmico. Já a vantagem do uso do *downscaling* estatístico é que ele oferece uma solução

imediate a um baixo custo computacional e, conseqüentemente, pode ser rapidamente implementado em centros operacionais.

Durante muito tempo, diversas abordagens menos complexas e menos onerosas como o *downscaling* estatístico davam resultados sistematicamente comparáveis ou mesmo superiores aos do *downscaling* dinâmico. No entanto, os modelos dinâmicos ganharam espaço e as técnicas estatísticas, ao invés de se contraporem a estes, têm passado a cumprir um papel complementar, seja como modelos de previsão autônomos, seja como corretores dos modelos dinâmicos.

2.10 Abordagem híbrida de previsões climáticas

As condições dos preditores climáticos para qualquer modelo empírico de previsão climática sazonal nos trópicos devem ser baseadas no princípio de que, nessa região, as condições de contorno na superfície (como a exemplo, a temperatura da superfície do mar - TSM) condicionam as características estatísticas significativas do clima. Montar um modelo linear de previsão consiste em construir uma equação de regressão linear múltipla com fortes relações estatísticas; por isso a relevância em escolher um bom conjunto de preditores. A TSM apresenta uma relação significativa com a precipitação sobre a região NE do Brasil, e por sua influência nas chuvas é que podemos utilizar a TSM como um preditor da precipitação.

A modelagem híbrida e/ou combinada consiste na integração de métodos preditivos individuais (DE BRITO PEREIRA *et al.*, 2016), diversos aspectos da não linearidade do clima não podem ser representados por modelos estatísticos simples, particularmente aqueles baseados em relações lineares, como os que utilizam regressões lineares múltiplas, análise de componentes principais ou análise de correlações canônicas. Por isso, a ideia de combinar o conhecimento estatístico com a modelagem dinâmica será usada neste trabalho, assim como foi proposto por MADDEN (1981): a formulação de um modelo híbrido simples.

A combinação de modelos estatísticos (obtidos da análise estatística de dados observados) com modelos dinâmicos (obtidos das leis físicas) surgiu em resposta ao papel fundamental exercido pelo oceano no fenômeno ENSO. Tal acontecimento constituiu os chamados modelos acoplados híbridos (hybrid coupled models- HCM), um termo aparentemente proposto por NEELIN (1989, 1990).

Tais modelos são compostos de um modelo de circulação geral oceânico (MCGO) acoplado a um modelo atmosférico mais simples, de complexidade muito aquém de um modelo de circulação geral da atmosfera (MCGA). Um exemplo de tal modelo pode ser encontrado em LATIF e FLÜGEL (1991). Em CHANG *et al.* (2001) e em BARNETT *et al.* (1993) o HCM provou ser uma ferramenta extremamente valiosa na modelagem nos estudos de interação oceano-atmosfera tropical.

3. MATERIAL E MÉTODOS

3.1 Dados observados

Desde 2016, Xavier *et al.* (2016) lançaram um conjunto de dados meteorológicos de análise gradeada referente ao período 1980-2013 a fim de prover informações de diversas variáveis para todo o território brasileiro. Essa grade tem resolução espacial de $0,25^\circ \times 0,25^\circ$ e foi utilizada em diversos estudos como base confiável de observação da superfície (DA ROCHA JR *et al.*, 2019; PAREDES-TREJO *et al.*, 2019; SILVA *et al.*, 2019; SILVA *et al.*, 2023).

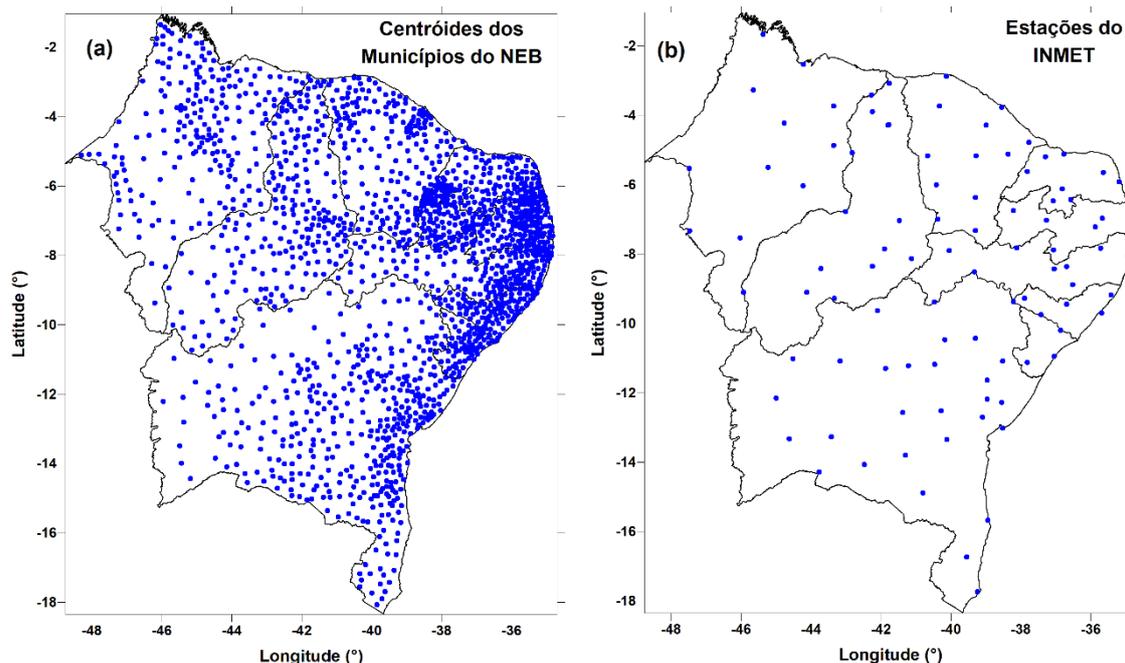
No entanto, Xavier *et al.* (2022) atualizaram essa análise gradeada tanto na resolução temporal, de 1961 até 2020, quanto na espacial com $0,1 \times 0,1^\circ$. Em relação à precipitação, essa foi a variável que contou com a maior quantidade de observações de superfície para a construção da grade, com um incremento de 316% de postos pluviométricos a mais do que na análise disponibilizada para 1980-2013. A maior parte dos dados pluviométricos foram oriundos do INMET, ANA e agências estaduais de Meteorologia espalhadas pelos estados brasileiros. Apesar do aumento no número de dados, a BLA contou, por exemplo, com uma média de um pluviômetro a cada 76 km para os anos de 1991-2020, ante um pluviômetro a cada 150 km para os anos de 1961-1980. Como descrito em seu trabalho, os dados foram expostos a um rigoroso controle de qualidade e em seguida interpolados seguindo os melhores resultados obtidos via validação cruzada entre os métodos de ponderação de distância inversa (IDW) e ponderação de distância angular (ADW), para geração de uma grade em alta resolução de $0,1^\circ \times 0,1^\circ$.

Dessa forma, foi possível extrair 1.794 séries temporais de dados diários de precipitação para cada município do NEB (Figura 2a), que foram então acumulados em séries mensais. Apesar da disponibilidade de dados de 1961 a 2022, utilizou-se o período 1991-2020 para coincidir com o período de hindcast disponibilizado pelo NMME.

Para demonstrar a confiabilidade dos dados dessa análise gradeada, foram utilizados dados de precipitação das 96 estações meteorológicas convencionais do Instituto Nacional de Meteorologia (INMET) no NEB (Figura 2b), e respectivamente, dados da análise para as mesmas coordenadas dessas estações para comparar-se a climatologia observada do período 1991-2020 com a da análise gradeada, as respectivas

diferenças e parâmetros estatísticos como a correlação de Pearson (r), o viés (*bias*), e a raiz do erro quadrático médio (*RMSE*), que são melhor descritos no tópico sobre índices de verificação.

Figura 2 - (a) Centróides dos municípios do NEB e (b) Distribuição geográfica das 96 estações meteorológicas convencionais nos estados do NEB



Fonte: Autor, 2024.

3.2 Dados do NMME

O North American Multi-Model Ensemble (NMME) é um sistema de previsão sazonal que acoplou modelos de renomados centros dos Estados Unidos e Canadá, como NOAA (*National Oceanic and Atmospheric Administration*), NCEP (*National Centers for Environmental Prediction*), GFDL (*Geophysical Fluid Dynamics Laboratory*), NCAR (*National Center for Atmospheric Research*), NASA (*National Aeronautics and Space Administration*) e CMC (*Canadian Meteorological Centre*).

Além dos modelos individuais para cada um dos centros mencionados, o NMME é um produto único resultante da integração da previsão de todos os modelos disponíveis. O NMME surgiu da necessidade de avaliar previsões e previsibilidades climáticas intra-sazonais e interanuais, para atender às necessidades regionais específicas de previsões sazonais e para apoiar a tomada de decisões por uma grande comunidade de usuários de informações climáticas. O NMME prova ser mais eficaz em comparação com qualquer

um dos modelos individuais que o compõem. O CPC (*Climate Prediction Center*) da NOAA é o órgão responsável por disponibilizar gratuitamente aos usuários tanto os *hindcasts* quanto as previsões de cada modelo individual, bem como o ensemble (NMME). Centros de previsão climática de todo o mundo utilizam dados do NMME de forma cada vez mais operacional (KIRTMAN *et al.*, 2014).

3.2.1 Modelos individuais do NMME

O NMME está atualmente em sua segunda fase. Esta fase inclui os seguintes modelos:

1) CFSv2 (*Climate Forecast System* versão 2): Este modelo representa uma interação global entre oceanos, terra e atmosfera e é operado pela NOAA/NCEP. É um modelo totalmente acoplado que é executado quatro vezes por dia, fornecendo dados horários com resolução de até meio grau para muitas de suas variáveis de saída. O CFSv2 usa técnicas recentes de assimilação de dados para consumir observações de diferentes fontes de dados, incluindo observações de superfície, radiossondas, aeronaves e observações de satélite. Mais informações sobre o modelo podem ser encontradas em SAHA *et al.* (2014).

2) GEOS-5 (*Goddard Earth Observing System*, versão 5): Operado pela NASA, é um modelo do sistema terrestre que envolve um conjunto de diferentes componentes em uma estrutura modular. O primeiro módulo é um modelo da circulação geral da atmosfera; o segundo módulo é um modelo de circulação geral dos oceanos; o terceiro módulo acopla os dois primeiros em um modelo de circulação geral atmosfera-oceano que inclui uma representação da criosfera, bem como uma representação de aerossóis atmosféricos; além de um módulo de química do clima, que permite conectar a composição química e a circulação geral atmosférico-oceânica, e um modelo de transporte químico, que permite o cálculo de reações químicas em um sistema baseado nas condições esperadas de ventos, temperaturas, umidade e distribuição de nuvens. Informações detalhadas podem ser encontradas em VECCHI *et al.* (2014).

3) CCSM4 (*Community Climate System Model* versão 4): Operado pelo NCAR, é um modelo climático acoplado para simular o sistema climático da Terra. Composto por cinco modelos separados que simulam simultaneamente a atmosfera da Terra, oceano, terra, gelo terrestre e gelo marinho, além de um componente de acoplamento central, o

CCSM permite que os pesquisadores realizem experimentos sobre os estados climáticos passados, presentes e futuros da Terra. Informações detalhadas podem ser encontradas em INFANTI e KIRTMAN. (2016).

4) Modelos operados pelo GFDL (*Geophysical Fluid Dynamics Laboratory*): Existem duas versões do modelo GFDL para o NMME, o GFDL CM2.1 (DELWORTH *et al.*, 2006) e o GFDL_FLOR (*Forecast-oriented Low Ocean Resolution*). Em fevereiro de 2021, essas duas versões foram substituídas pelo GFDL_SPEAR (*Seamless System for Prediction and Earth System Research*). Esta versão foi desenvolvida para previsões sazonais e projeções multidimensionais. O GFDL_SPEAR possui um modelo atmosférico com resolução de 1° e 33 níveis verticais e simulação de aerossóis, um modelo oceânico com resolução de 1 a 4° e 75 níveis, um modelo de gelo marinho com transferência radioativa compatível com o modelo oceânico e um modelo terrestre de cobertura da terra com vegetação dinâmica. Segundo HELD *et al.* (2019), esta versão apresenta uma simulação muito boa da climatologia atual e da variabilidade do ENOS (El Niño Oscilação Sul).

5) Modelos Canadenses: Operados pelo Centro Meteorológico Canadense, os modelos CMC1-CanCM3 e CMC2-CanCM4 foram descontinuados e substituídos por CanCM4i e GEM_NEMO a partir de agosto de 2019. São modelos climáticos acoplados que assimilam melhor as condições iniciais do clima, gelo e temperatura da superfície do mar. O GEM_NEMO é um modelo acoplado global atmosfera-oceano baseado em um modelo numérico de previsão do tempo recentemente desenvolvido. Mais informações podem ser encontradas em MERRYFIELD *et al.* (2013) e LIN *et al.* (2020).

3.2.2 *Hindcasts* do NMME

Cada modelo, além do próprio NMME, fornecia um conjunto completo de *hindcasts* para 1982-2010 por até seis meses/trimestres a partir do mês de sua inicialização. Recentemente, os *hindcasts* foram atualizados e estão disponíveis para o período 1991-2020, a fim de concordar com a última normal climatológica oficial da OMM e continuar oferecendo 30 anos de dados históricos de previsões. Essas previsões retrógradas são usadas para calibração de modelos e estudos aplicados. As previsões em tempo real para cada mês, disponibilizadas a partir de 2021, são feitas pelo CPC/NCEP e estão disponíveis entre os dias 8 e 11 de cada mês, com três variáveis disponíveis:

temperatura da superfície do mar, temperatura média a 2 metros e taxa de precipitação, em resolução global de $1,0^\circ \times 1,0^\circ$ de latitude/longitude, para todos os membros (modelos) do conjunto (NMME).

Para o *hindcast* de um mês/trimestre típico, haverá 7 arquivos de precipitação e 7 para temperatura média de cada modelo e do NMME, o que contabiliza um total de 168 arquivos de *hindcasts* para os doze trimestres do ano no período 1991-2020. Em nível mensal (três meses individuais de cada trimestre), tem-se 504 arquivos de *hindcasts* de precipitações e temperaturas médias mensais para os doze trimestres do ano no período 1991-2020.

A tarefa operacional consiste em calibrar os dados brutos dos modelos NMME com os arquivos de dados observados de precipitação oriunda da análise gradeada de Xavier *et al.* (2022), a fim de comparar e identificar quais os modelos mais confiáveis para a produção de previsões climáticas quando comparadas aos resultados obtidos com as observações.

3.2.3 Organização dos dados para calibração do NMME

O NMME fornece dados agregados de modelos dinâmicos individuais (descritos no tópico 3.2.1), de *hindcasts* e previsões, em formatos binário e ascii (descritos no tópico 3.2.2). Os dados do NMME estão disponíveis para download via ftp, em escalas de tempo mensais e sazonais, atualizados mensalmente.

Para configurar um esquema automatizado para gerar essas previsões, as seguintes etapas foram realizadas:

1. Download dos dados dos *hindcasts* e das previsões do link: <https://ftp.cpc.ncep.noaa.gov/International/nmme/>;
2. Combinações dos *hindcasts* e previsões de um determinado mês/trimestre em um único arquivo;
3. Criação uma base de dados de precipitação observadas mensalmente a partir de dados em grade regular (XAVIER *et al.* 2022).
4. Download dos dados da grade de Xavier, em formato netcdf e gerar séries temporais de precipitação, com a mesma resolução do NMME ($1^\circ \times 1^\circ$), ou superior, para comparação direta com o histórico dos modelos.

5. Obtenção de séries temporais de precipitação mensal para cada município do NEB para a etapa de pós-processamento dos resultados do NMME, calibrando as previsões retrógradas do NMME, e de seus modelos individuais, usando a técnica de ACC, para 30 anos de *hindcast* (1991/2020);

6. Gerar quatro produtos principais de previsão, apresentados em formatos de mapa e/ou metadados para pontos de estação e/ou pontos de grade:

(a) Correlação entre previsões calibradas e observações (*hindcast* calibrado para o período 1991-2020);

(b) Previsão de precipitação acumulada mensal;

(c) Desvio da precipitação prevista em relação à climatologia de referência coincidindo com o período de *hindcast* (1991/2020);

(d) Previsão probabilística, em tercís, da precipitação do mês/trimestre.

3.2.4 Calibração de previsões climáticas com ACC

O NMME reúne resultados de centros de referência internacionais na produção de previsões climáticas. No entanto, mesmo esses sistemas não estão imunes às incertezas decorrentes da natureza caótica da atmosfera e dos erros associados às condições iniciais. Previsões brutas de um modelo climático global podem exibir tendências indesejáveis (viés) e muitas vezes não mostram poder superior a uma simples previsão baseada em climatologia (SHUKLA e LETTENMAIER, 2013; SCHEPEN e WANG, 2014).

Portanto, há benefícios significativos na aplicação de metodologias de pós-processamento às previsões climáticas. Várias técnicas podem ser utilizadas para resolver tais problemas, buscando extrair o máximo de habilidade das previsões (ZHAO *et al.*, 2017). Essas técnicas vão desde combinar diferentes modelos usando uma abordagem Bayesiana para obter melhores resultados (COELHO *et al.*, 2006; COELHO *et al.*, 2007), regressão por conjuntos (UNGER *et al.*, 2009; OU *et al.*, 2016; COLLINS, 2017; OSMAN *et al.*, 2021), modelos de probabilidade conjunta (WANG *et al.*, 2009; WANG e ROBERTSON., 2011), entre outros métodos estatísticos de pós-processamento ou calibração (GNEITING *et al.*, 2005; WILKS e HAMILL., 2007; SACHINDRA *et al.*, 2013; SCHEPEN *et al.*, 2014; BENESTAD *et al.*, 2015; ZHANG *et al.*, 2017; NARAPUSETTY *et al.*, 2018). Dentre as diversas técnicas existentes para correção de erros sistemáticos nos modelos, utilizaremos a ACC.

A ACC é um método estatístico que identifica um par de padrões em dois conjuntos de dados multivariados e gera variáveis transformadas que projetam os padrões da série original. ACC é aplicado como um método de *downscaling* e correção de viés dos resultados do modelo, melhorando suas previsões usando relações estatísticas entre as variáveis observadas e previstas pelo modelo. Muitas vezes, essas relações estatísticas têm uma base física, absorvendo sinais de fenômenos de grande escala (por exemplo, fase ENOS), que influenciam as previsões.

A ACC pode ser usada de duas maneiras, primeiro como um modelo de previsão puramente estatístico que relaciona padrões de anomalias em observações (por exemplo, anomalias de temperatura da superfície do mar) a padrões de anomalias climáticas nos próximos meses ou trimestres (por exemplo, anomalias de precipitação) baseado em um longo período de anos, sem envolver nenhum modelo dinâmico (CHU e HE., 1994; CHU, 1998; LANDMAN e MASON., 1999; COLLINS *et al.*, 2004; CHOWDHURY *et al.*, 2007; JUNENG e TANGANG., 2008). A segunda forma de utilização da ACC, e que será usada nesta pesquisa, é relacionar os dados brutos da previsão de precipitação oriundas de um modelo para um determinado mês, com a correspondente observação da variável de interesse em um período retrospectivo (BUSUIOC *et al.*, 2008; LIM *et al.*, 2011; apud BARNSTON e TIPPETT., 2017). Os dados brutos do modelo são os preditores e as observações são os preditandos.

3.3 Fundamentação teórica da ACC

A ACC é um método linear multivariado utilizado para comparar dois conjuntos de dados: um independente X , também conhecido como variáveis explicativas (preditores), e outro dependente Y , também conhecido como variáveis de resposta (preditandos), composta por um número p de variáveis X_i e q variáveis Y_i , respectivamente.

É um método utilizado para identificar a influência de uma variável sobre outra variável, a fim de encontrar a melhor combinação linear e a máxima correlação entre as duas variáveis. O ACC está acima da hierarquia dos modelos de regressão (apud BARNETT e PREISENDORFER, 1987), tendo como vantagem sobre 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). É particularmente útil em situações em que várias medidas de resultados devem estar disponíveis, como em previsões meteorológicas (DÍAZ e VILLEGAS, 2015).

Na ACC, são criadas combinações lineares x^* e y^* , chamadas variáveis canônicas (VC), com ao menos duas variáveis de cada conjunto:

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

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

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

onde r_c é a correlação canônica. O cálculo da VC é realizado a partir das matrizes de variância e 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 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 os 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 satisfaçam:

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

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

Os valores de α e β revelam quais variáveis têm maior força explicativa dentro da correlação e são importantes na construção de um modelo preditivo (apud WILKS, 2011; apud SINGH *et al.*, 2012). Além de α e β na ACC, as cargas canônicas (CC) e as cargas canônicas cruzadas (CCC) também são calculadas. As CC permitem conhecer a contribuição de cada variável observada x_i e y_i para seus respectivos VC x^* e y^* . As CCs independentes são as correlações lineares entre x_i e x^* , e as CC dependentes entre y_i e y^* .

As CCCs fornecem informações mais significativas sobre a relação entre as variáveis observadas e as novos VCs (KATZ *et al.*, 2003). Os CCCs independentes são as correlações lineares entre x_i e y^* e as CCC dependentes entre y_i e x^* . Por fim, na ACC, é calculado o coeficiente de redundância, que permite estabelecer o percentual de variância explicada no conjunto de variáveis dependentes, com base no conjunto de variáveis independentes (apud KATZ *et al.*, 2003).

3.4 Ferramenta de previsibilidade

Para o nosso propósito, o ACC limita-se a associar índices a cada um dos conjuntos de dados (X: explicativo (preditor) e Y: resposta (preditando), definidos como combinações lineares dos valores em cada um dos conjuntos (Função ortogonal empírica - FOE), maximizando a correlação entre os dois índices, retendo o máximo de informação possível das variáveis originais. Nesta pesquisa, a variável explicativa é a precipitação simulada pelos modelos NMME, e a variável resposta será a precipitação observada. Aplicações semelhantes podem ser encontradas em STUDZINSKI (1995), DIAZ *et al.* (1998), REPELLI e NOBRE (2004), apud DA ROCHA JÚNIOR *et al.*, (2021).

Existem algumas possibilidades de softwares e pacotes estatísticos disponíveis para aplicação da técnica de ACC, destacando-se: SPSS Statistics, Python e R Statistics. Nesta pesquisa foi utilizado o software CPT (Climate Predictability Tool), versão 15.6.3. Alguns trabalhos foram desenvolvidos utilizando esta ferramenta de previsibilidade climática (LUCIO *et al.*, 2010; KIPKOGI *et al.*, 2017; ESQUIVEL *et al.*, 2018; LANDMAN *et al.*, 2019). O CPT é um software desenvolvido pelo IRI (International Research Institute for Climate and Society – Columbia University), voltado para construção de modelos de previsão climática sazonal, simulações e validações de modelos (MASON e TIPPETT, 2017; IRI, 2019).

O CPT utiliza dois conjuntos de dados nas simulações. O primeiro conjunto de dados contém as "variáveis X", chamadas de "preditores", "variáveis independentes" ou "variáveis explicativas". Essas variáveis X são usadas para prever as variáveis no segundo conjunto de dados, que deve conter as "variáveis Y", que são chamadas de "preditados", "variáveis dependentes" ou "variáveis de resposta".

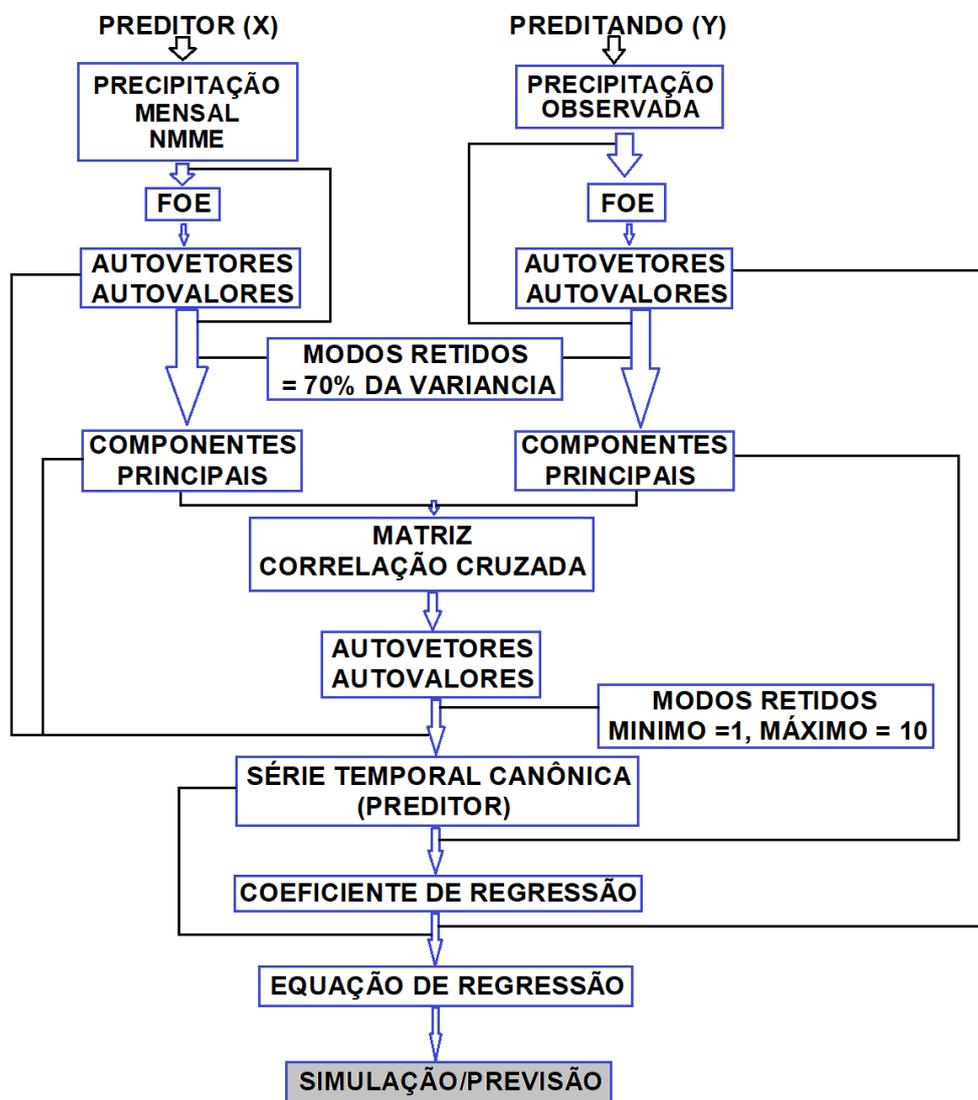
Neste trabalho foram utilizados os dados mensais de chuva dos modelos do NMME como variáveis explicativas, ou preditoras (X) e as observações mensais como

variáveis de resposta, ou preditando (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. A Figura 3 ilustra de forma esquemática as etapas necessárias para as simulações da precipitação regionalizada para o NEB (preditando Y) em função dos campos de precipitação acumulada mensais simuladas pelo NMME e modelos que o compõem (preditor X).

Figura 3 - Esquema ilustrativo das etapas utilizadas para a calibração e previsão da precipitação para o NEB a partir da precipitação do NMME



Fonte: Autor, 2023.

3.5 Índices de verificação

Os prognósticos climáticos possuem muitas incertezas associadas, já que não dependem exclusivamente das lentas variações de certas condições observadas na superfície terrestre, como a temperatura da superfície dos oceanos e umidade dos solos. Nesse sentido é fundamental descrever e implementar procedimentos de verificação dos prognósticos, antes e depois do pós-processamento com ACC, a fim de mensurar os ganhos impostos por essa técnica de *downscaling* estatístico.

As previsões calibradas possuem duas saídas, a determinística e a probabilística. Nessa pesquisa, trabalhou-se com as saídas determinísticas por acreditar-se que essas têm mais utilidade para a tomada de decisões por diferentes setores da sociedade do que previsões probabilísticas.

Nesse sentido, é um objetivo específico da pesquisa disponibilizar um conjunto de métricas de verificação que permita avaliar a performance do NMME e de cada modelo que o compõe, para as previsões de precipitação mensal. Para as previsões determinísticas, foram calculados o coeficiente de correlação de Pearson (r), o erro médio absoluto (MAE) e o erro quadrático médio (RMSE). Cada índice é descrito em detalhes a seguir.

3.5.1 Erro Médio Absoluto (MAE)

Mede a magnitude média dos erros em um conjunto de previsões, independentemente de sua direção. É a média sobre uma amostra de observações e previsões da qual a diferença "previsão-observação" é extraída, com pesos iguais para todas essas diferenças. Nota: caso não seja obtido um valor absoluto, o MAE passa a ser MBE (Mean Bias Error) e neste caso serve como parâmetro para medir a tendência média do modelo. O MBE transmite informações úteis, mas deve ser interpretado com cautela, pois erros positivos e negativos tendem a se anular em amostras imparciais.

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_i - O_i| \quad (8)$$

onde N é o número total de elementos na amostra, p = pronósticos e o = observações em cada momento i .

3.5.2 Erro quadrático médio (RMSE)

É uma pontuação ao quadrado que também mede a magnitude média do erro. É a raiz quadrada da média das diferenças quadradas entre a previsão e a observação real.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad (9)$$

- Comparação entre MAE e RMSE:

Semelhanças: Tanto o MAE quanto o RMSE expressam o erro médio de predição do modelo em unidades da variável de interesse. Ambas as métricas podem variar entre

0 e ∞ e são indiferentes à direção dos erros. Estas são pontuações com viés negativo, o que significa que pontuações mais baixas são melhores.

Diferenças: Obter a raiz quadrada dos erros quadráticos médios tem algumas implicações interessantes para o RMSE. Como os erros são elevados ao quadrado antes de serem calculados, o RMSE atribui um peso relativamente alto a erros grandes. Isso significa que o RMSE deve ser mais útil quando grandes erros são particularmente indesejáveis.

3.5.3 Correlação de Pearson (r)

O coeficiente de correlação de Pearson mede a força da relação linear entre observações e previsões (Equação 10). Varia entre [-1,1]. Pontuação perfeita: 1. O coeficiente de correlação de Pearson entre duas variáveis (observações (o) e previsões (p)) é definido como a covariância das duas variáveis ($Cov(o, p)$) dividida pelo produto de seus desvios padrão ($\sigma(o, p)$).

$$r_{o,p} = \frac{Cov(o, p)}{\sigma(o, p)} \quad (10)$$

Como forma de auxiliar na análise estatística do coeficiente de correlação, será utilizada a tabela a seguir, onde é apresentada uma interpretação detalhada do coeficiente de correlação de Pearson.

Tabela 2 - Classificação dos intervalos de correlação e definição da relação entre os dados simulados por um modelo e os dados observados

Limites	Definição
0,00 a 0,19	Correlação muito fraca
0,20 a 0,39	Correlação fraca
0,40 a 0,69	Correlação moderada
0,70 a 0,89	Correlação forte
0,90 a 1,00	Correlação muito forte

Fonte: Devore (2006).

Para garantir que o valor de r realmente expresse a concordância entre observações e simulações, será utilizado o teste *t-Student* paramétrico (AL-ACHI., 2019) para avaliar o grau de relacionamento entre as variáveis em questão. Uma premissa para

a utilização do teste é que o tamanho da amostra, N , a partir do qual o valor do coeficiente de correlação, r , é obtido, seja igual ou maior que 6, então o valor de t é dado pela (Equação 11):

$$t = \frac{r}{\sqrt{\frac{(1-r^2)}{(N-2)}}} \quad (11)$$

A Equação 11 é uma distribuição para t com $N-2$ graus de liberdade. A aplicação desta fórmula a qualquer valor de r e N testará a hipótese nula de que o valor observado vem de uma população na qual não há correlação significativa entre os dados. Uma vez obtido o valor de t , pode-se extrair o coeficiente de correlação crítica (r_c), que é um valor para o qual se aceita ou não a hipótese estatística de que existe uma correlação entre os dados simulados e observados, r_c é dado por:

$$r_c = \sqrt{\frac{t^2}{(N-2) + t^2}} \quad (12)$$

4. RESULTADOS

4.1 Análise dos dados de Xavier para o Nordeste.

Um dos principais critérios usados na avaliação de desempenho de qualquer fonte de dados é se a condição histórica observada pode ser ou não replicada em termos médios. Portanto torna-se indispensável que determinado conjunto de dados gere séries temporais que tenham as mesmas propriedades dos dados meteorológicos observados, resultando em boa correlação entre ambos e que apresentem habilidade em caracterizar a climatologia de um período de referência (COSTA *et al.*, 2020; COSTA *et al.*, 2021).

A Figura 4 mostra o ciclo médio anual da precipitação acumulada no período 1991-2020 no NEB com as observações do INMET, e obtida da análise gradeada de Xavier (Figura 5), para as mesmas coordenadas das estações do INMET. Percebe-se a forte coerência entre as climatologias, um forte indicativo da confiabilidade dos dados de Xavier, devido a sua eficiência na representação do ciclo anual climatológico da precipitação acumulada mensal.

Devido à baixa densidade de estações, suas coordenadas geográficas foram usadas para extrair da análise gradeada de Xavier, séries para essas mesmas coordenadas por meio do método de interpolação bilinear simples (DA ROCHA JÚNIOR *et al.*, 2019). Esse método calcula um valor para as coordenadas das estações de interesse, atribuindo pesos característicos a cada um dos quatro pontos de grade que circundam a localização geográfica de uma estação, com pesos maiores quanto mais próximo estiver o ponto de grade da coordenada da estação (LIU *et al.*, 2015). Isso permite uma comparação realística entre dados de estações meteorológicas e provenientes de análises gradeadas. Essa verificação quantitativa da precipitação observação x análise gradeada é utilizada em muitos estudos que tem atestado a sua eficácia (MICHOT *et al.*, 2018; RODRIGUES *et al.*, 2021; HERDIES *et al.*, 2023; SILVA *et al.*, 2023).

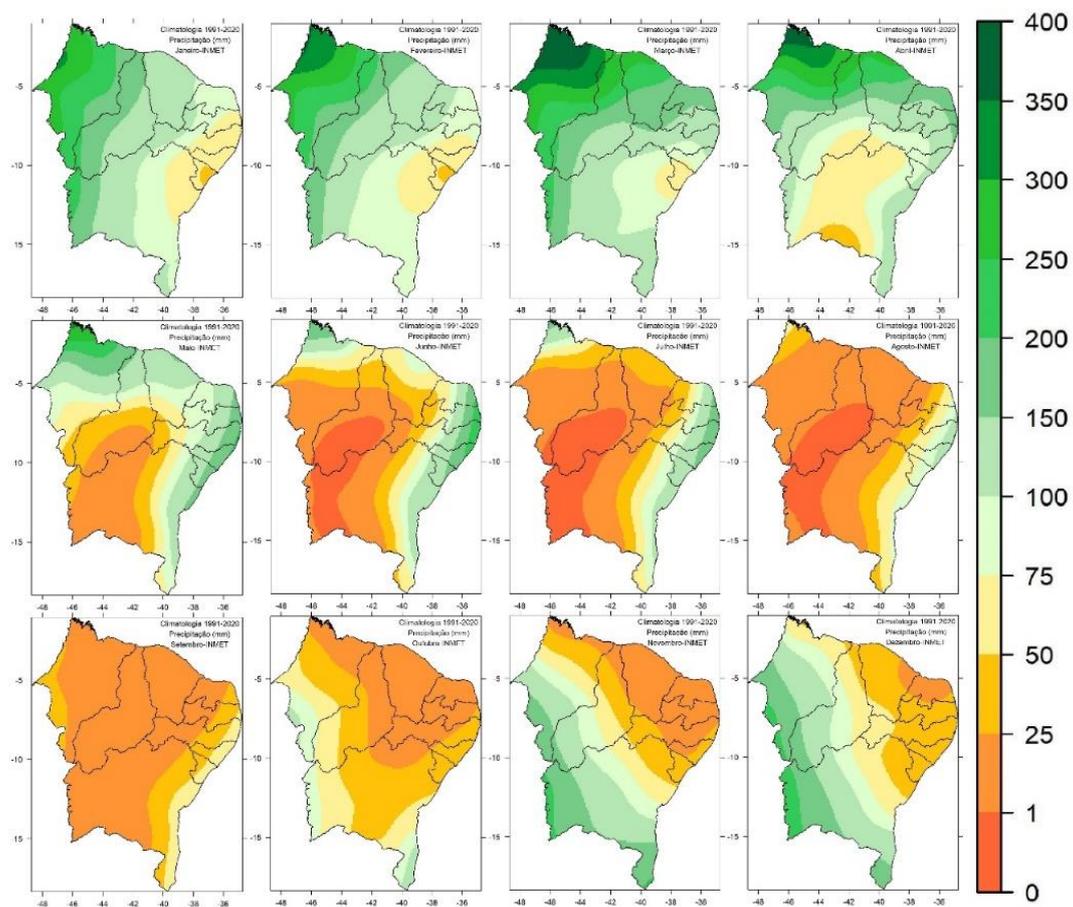
O período mais chuvoso no norte do NEB de janeiro a abril, no leste do NEB entre abril e junho, e no oeste do NEB de novembro a março, assim como os respectivos períodos mais secos, foram muito bem representados na climatologia obtida a partir da análise gradeada de Xavier.

No entanto, é preciso verificar as possíveis diferenças entre essa base de dados e as observações. Dessa forma, a Figura 6 mostra as diferenças entre as climatologias de

cada mês. Percebe-se uma diferença predominantemente negativa, com destaque para o leste do NEB de janeiro a julho, com valores entre 5mm a 25mm, e no oeste do NEB de novembro a março, mostrando que os dados de Xavier têm uma leve inclinação a subestimar a precipitação na maior parte do NEB.

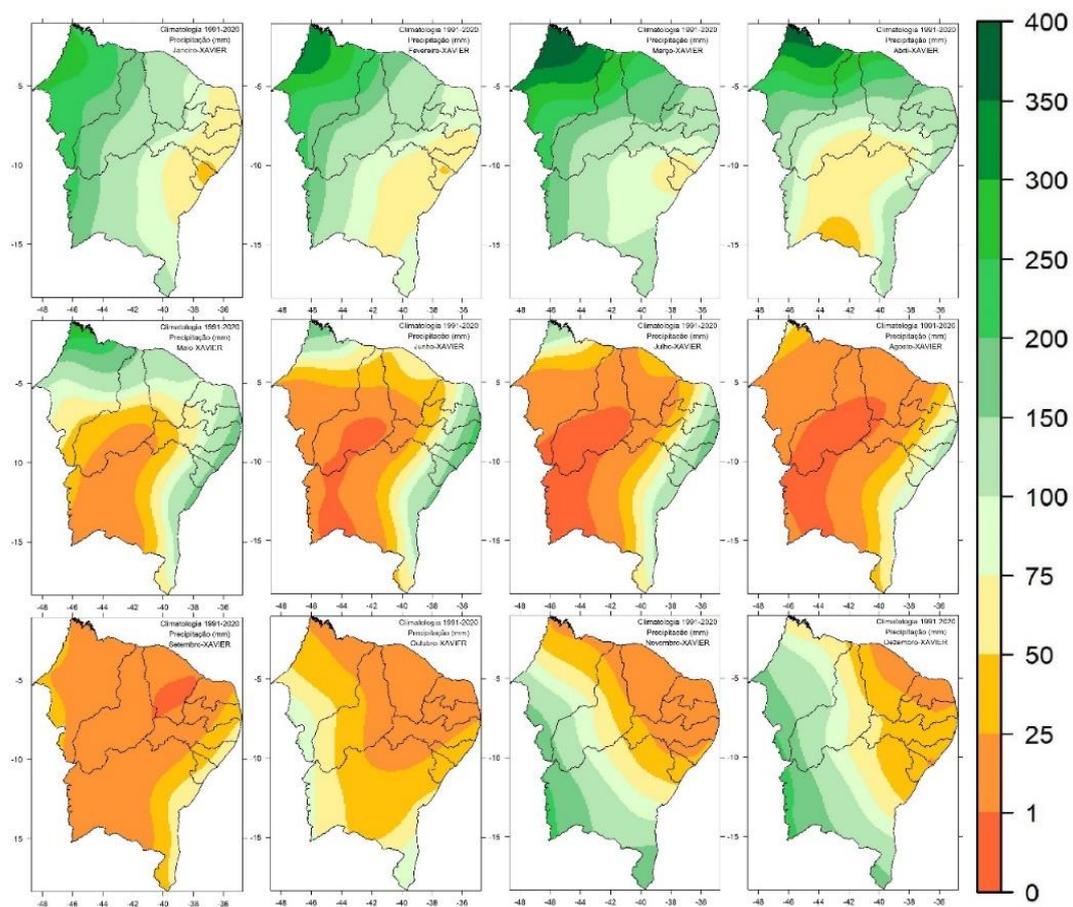
Para sintetizar os resultados da análise dos índices de verificação, mostra-se na Figura 7 o viés, a correlação, o MAE e o RMSE das séries contínuas, ou seja, não são resultados discreteados para um determinado mês do ano, mas que representam todos os meses em geral. O viés (Figura 7a), reflete a média das diferenças mensais apresentadas na Figura 5, com a vantagem de evidenciar mais claramente as áreas onde os dados de Xavier tendem a subestimar de forma sistemática a precipitação, que são nos extremos noroeste e oeste do Maranhão, em torno de 5 a 10 mm/mês, no nordeste do NEB entre os estados do Ceará, Rio Grande do Norte, Paraíba e Pernambuco de 5 a 25 mm/mês, e em núcleos isolados no centro e sul da Bahia, com subestimativa de 5 a 10 mm/mês. A Correlação média mensal (Figura 7b) evidencia a qualidade da análise gradeada no comportamento da variabilidade temporal dos dados observados, com correlações que superam 0,8 em todo o NEB. A MAE (Figura 7c) e o RMSE (Figura 7d) mostram que os erros da análise gradeada de Xavier são de fraca magnitude em relação as observações, alcançando máximos entre 25 a 50 mm no parâmetro MAE em porções do litoral nordestino entre Rio Grande do Norte e Alagoas, sul da Bahia e noroeste do Piauí e na maior parte do Maranhão, enquanto em relação ao parâmetro RMSE, se situa na maior parte do NEB com valores entre 25 a 50mm, e de 50 a 75mm no norte do Maranhão.

Figura 4 - Climatologia mensal da precipitação (mm) no NEB com dados do INMET no período 1991-2020



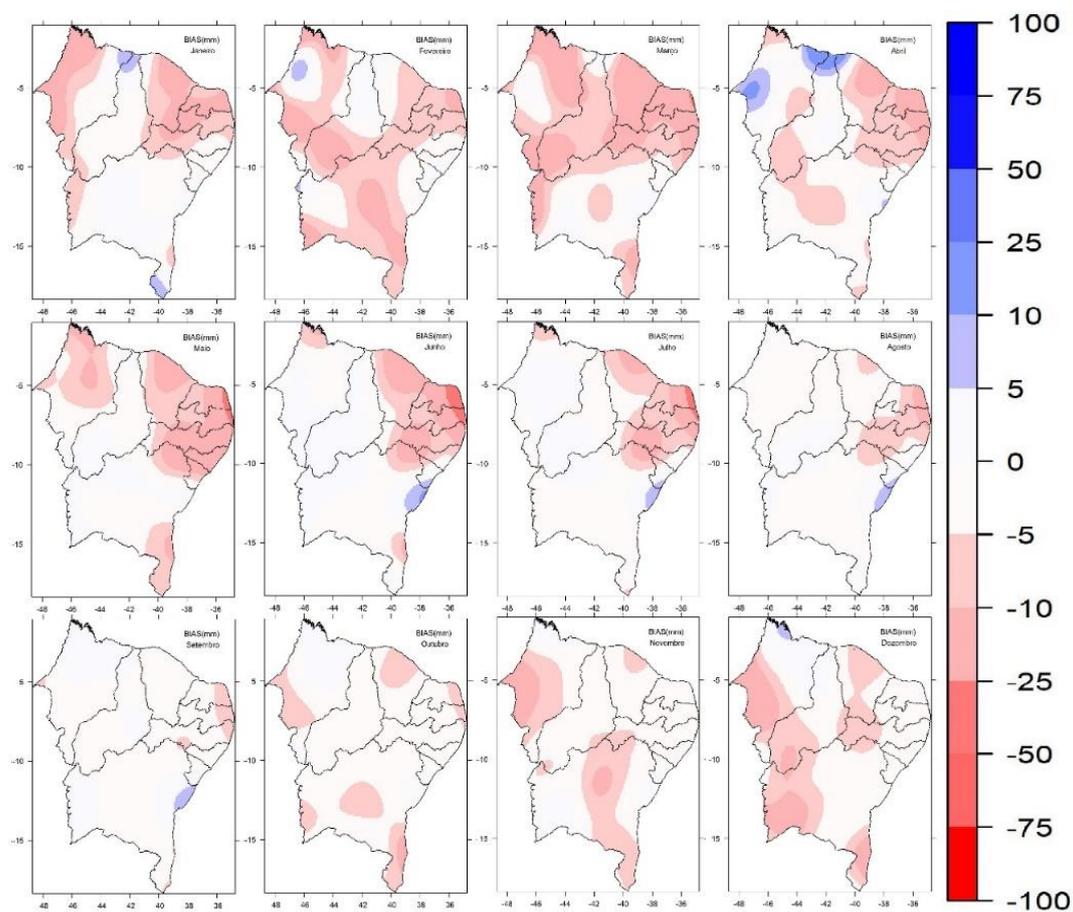
Fonte: Autor, 2023

Figura 5 - Climatologia mensal da precipitação (mm) no NEB com dados da análise gradeada de Xavier no período 1991-2020



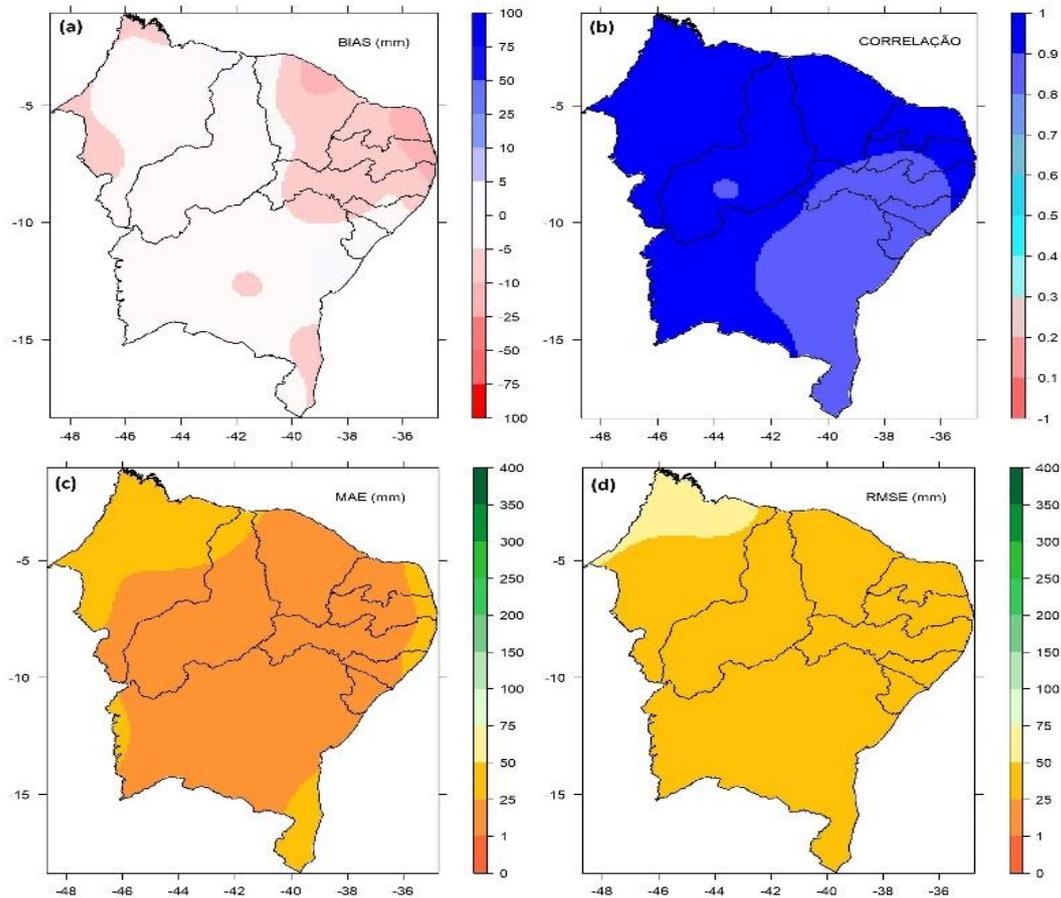
Fonte: Autor, 2023

Figura 6 - Diferença entre a climatologia mensal obtida com dados da análise gradeada de Xavier e observações do INMET para a precipitação no NEB no período 1991-2020



Fonte: Autor, 2023

Figura 7 - (a) Viés, (b) Correlação, (c) MAE e (d) RMSE, calculados entre observações e análise gradeada de Xavier para a precipitação mensal do NEB no período 1991-2020



Fonte: Autor, 2023

4.2 Climatologia bruta dos modelos NMME

Neste segmento, aborda-se uma análise detalhada da climatologia bruta resultante das previsões dos modelos do NMME (North American Multi-Model Ensemble), comparando-as com as observações reais (referenciadas como Xavier). Utilizamos uma amostra específica dos resultados gerados para exemplificar os demais, facilitando assim a visualização e compreensão do processo analítico, conforme apresentado na Figura 8. Esta amostra representa a previsão para o mês de abril, obtida a partir dos *hindcasts* (dados históricos) com início em janeiro. Ou seja, recorreremos ao lag3, referente aos meses anteriores (março/lag 1 – fevereiro/lag 2 – janeiro/lag 3), a fim de avaliar se os dados previstos se alinham com as observações reais.

Para garantir a comparabilidade e coerência nos resultados, foi necessário padronizar o grau de resolução das saídas dos modelos para 1° de latitude por 1° de

longitude. Isso exigiu um processo de equalização de resolução, através de um forçamento (regride), para assegurar que os programas de análise captassem as entradas de maneira uniforme, gerando os resultados necessários para esta análise.

O NEB experimenta três períodos distintos de chuvas, como identificado por Molion e Bernardo (2002). Eles observaram a formação de uma zona de convergência sobre o Oceano Atlântico, direcionada à costa leste do NEB entre os meses de abril a junho. Essa convergência, combinada com frentes frias e massas de ar úmido do Oceano Atlântico, resulta em um período de chuvas intensas na costa leste do Nordeste. Este período é seguido por outra fase de chuvas intensas, mais prevalentes no norte do NEB entre fevereiro, março e metade de abril, e no centro-oeste do NEB de novembro a janeiro. Portanto, o mês de abril assume importância crucial para o estudo em questão, influenciando as chuvas no norte do NEB e contribuindo significativamente para as condições pluviométricas no leste do NEB.

Na porção setentrional do Nordeste do Brasil, a ZCIT é o principal sistema de produção de chuvas. Formada pela confluência dos ventos alísios do Hemisfério Norte (alísios de nordeste) e os do Hemisfério Sul (alísios de sudeste), a ZCIT constitui-se no movimento ascendente do ar carregado de umidade que, ao se elevar, sofre resfriamento e condensação resultante na nebulosidade persistente na zona equatorial onde ocorrem as precipitações mais elevadas do planeta. Sua influência na pluviometria do Nordeste setentrional ocorre principalmente nos meses de março e abril, podendo em alguns anos se antecipar para fevereiro e/ou se prorrogar até maio. A ausência da ZCIT na região acima da bacia do rio São Francisco nos meses mencionados reduz a precipitação desde Pernambuco até a porção leste semiárida do estado do Piauí (SARMENTO, 2021).

O diagrama apresentado na Figura 8 ilustra um painel comparativo climatológico entre modelos de previsão e observações de precipitação para a região do Nordeste do Brasil. A análise diferencia as discrepâncias entre o que é previsto pelos modelos (coluna 2) e os dados observados (coluna 1).

No primeiro modelo, CFSV2, é notável uma tendência pronunciada de superestimar a precipitação no centro da Bahia. Enquanto as observações indicam valores de 50-75 mm para abril, o modelo prevê valores substancialmente superiores. A análise das diferenças entre as climatologias do modelo bruto e observado evidencia uma superestimação geral de 100 a 300 mm na maior parte do NEB.

O modelo CMC1, por sua vez, mostra uma tendência de subestimação no leste do NEB e superestimação no centro-oeste. Essa disparidade é mais evidente onde as observações registram menor precipitação, como no lado oeste da Bahia. A comparação das climatologias revela uma subestimação notável no leste, norte e centro-oeste do NEB e uma superestimação significativa no interior. Quanto ao modelo CMC2, há uma subestimação de chuvas no nordeste do NEB, abrangendo os estados do RN até o extremo norte da Bahia, enquanto valores mais elevados são previstos na parte oeste da região. As diferenças entre a climatologia observada e a do modelo bruto destacam essa disparidade, com subestimação nas regiões mencionadas e superestimação no oeste e interior do NEB.

O modelo GFDL estima valores mais altos de precipitação no noroeste do NEB, coincidindo com áreas já mais chuvosas nas observações. No entanto, também superestima a precipitação no centro da Bahia e em outras regiões do NEB, refletindo-se na discrepância entre as climatologias, com uma superestimação generalizada, exceto por uma parte do leste da Bahia. Já o modelo NASA, por sua vez, apresenta uma superestimação considerável em todo o NEB, especialmente no norte, com destaque para o estado do Maranhão, onde são previstos valores de até 400 mm além das observações. A análise das diferenças entre as climatologias destaca essa superestimação, evidenciando discrepâncias expressivas.

O modelo NCAR demonstra uma maior proximidade visual com as observações, especialmente no centro da Bahia, onde historicamente há menos chuvas. No entanto, apresenta tendência de superestimação mais acentuada no estado do Maranhão. A análise das diferenças revela uma menor superestimação ou subestimação em regiões específicas, representadas por áreas mais neutras no mapa.

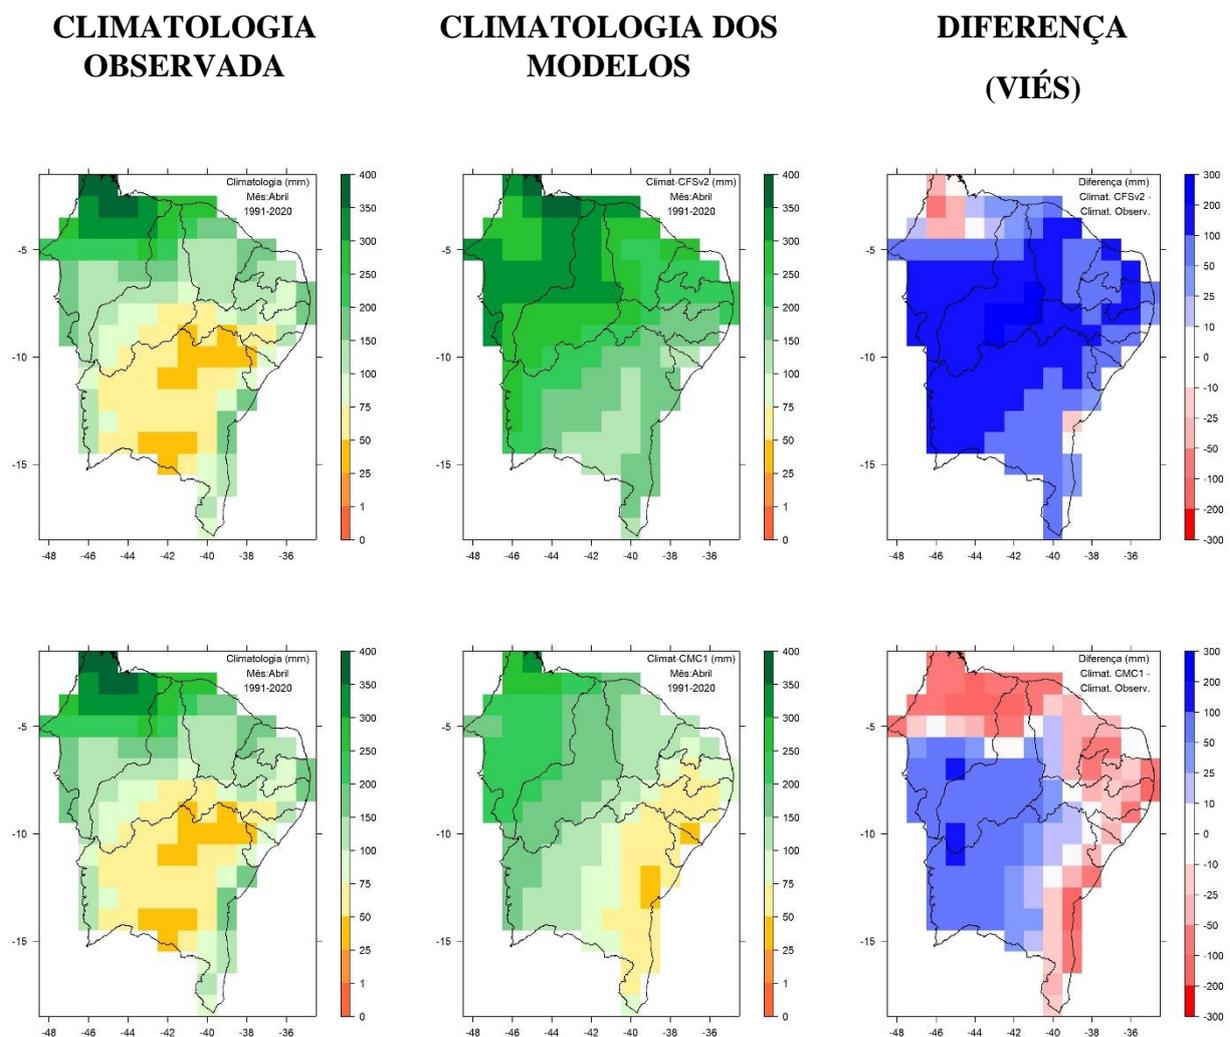
Por fim, o modelo NMME, representando a média dos seis modelos, também mostra uma tendência de superestimação em toda a região do NEB, com ênfase no noroeste (Maranhão e Piauí). A comparação das climatologias indica uma subestimação leve no leste da Bahia e no extremo norte do Maranhão, contrastando com a superestimação de até 300 mm no restante do NEB.

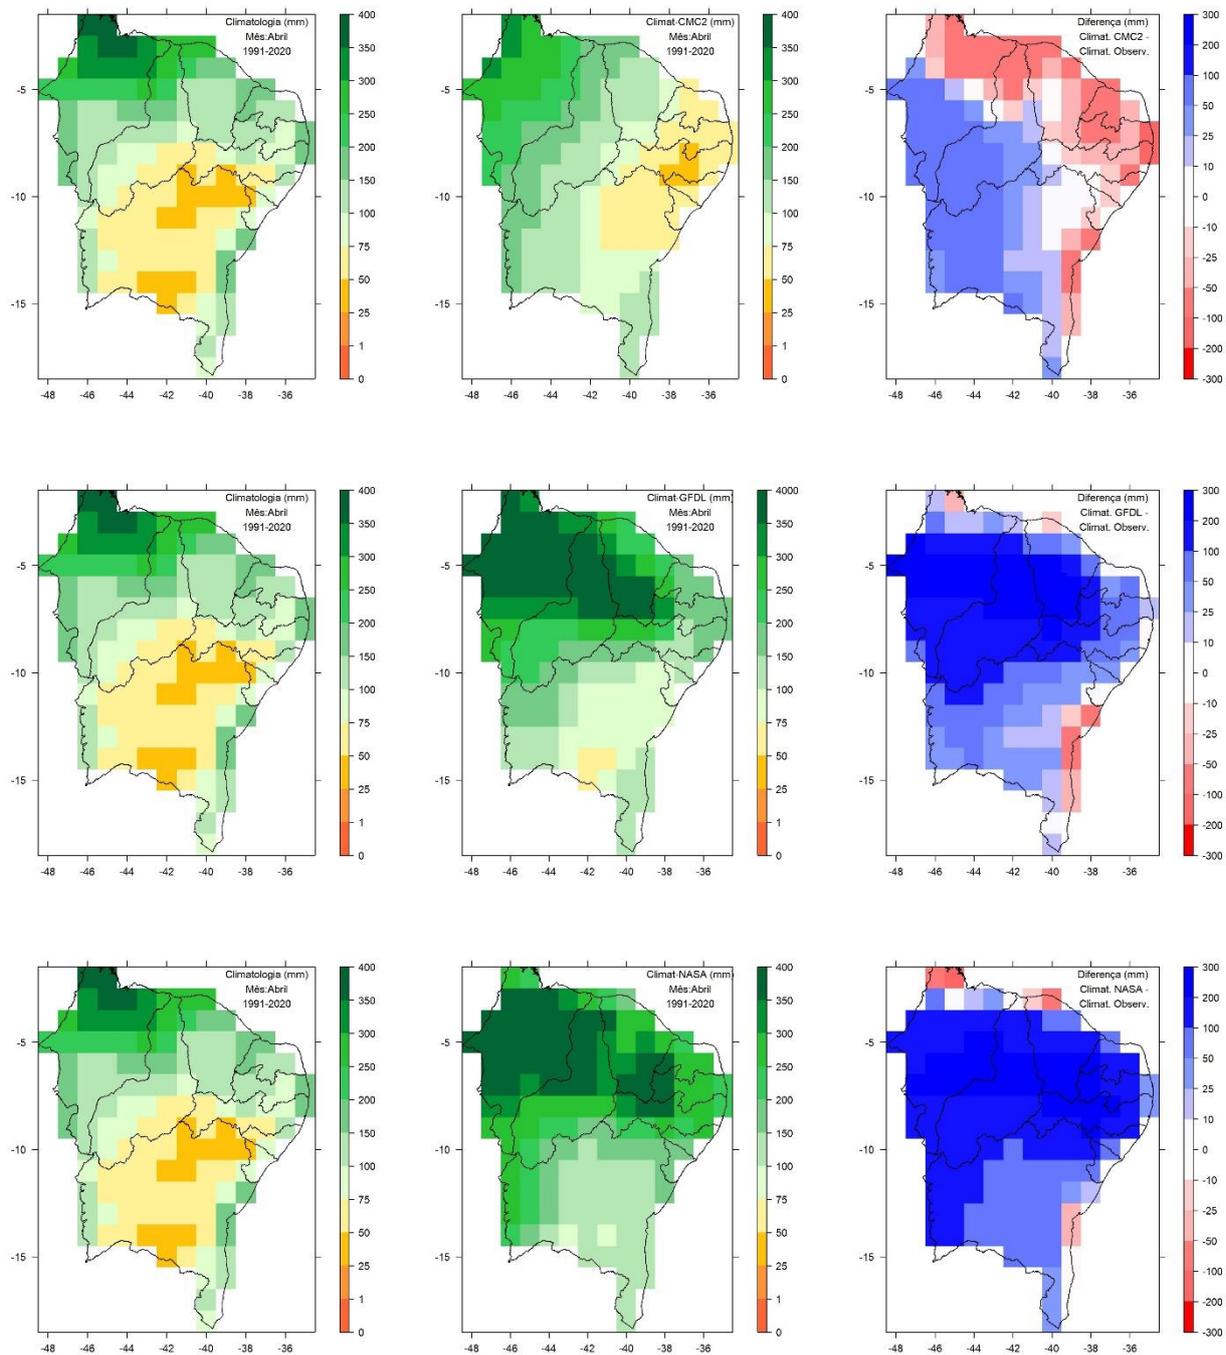
A análise detalhada dos modelos brutos em relação às observações de precipitação na região do NEB evidencia discrepâncias substanciais e variações significativas entre as projeções dos modelos e os dados reais. Essa análise crítica oferece justificativas sólidas

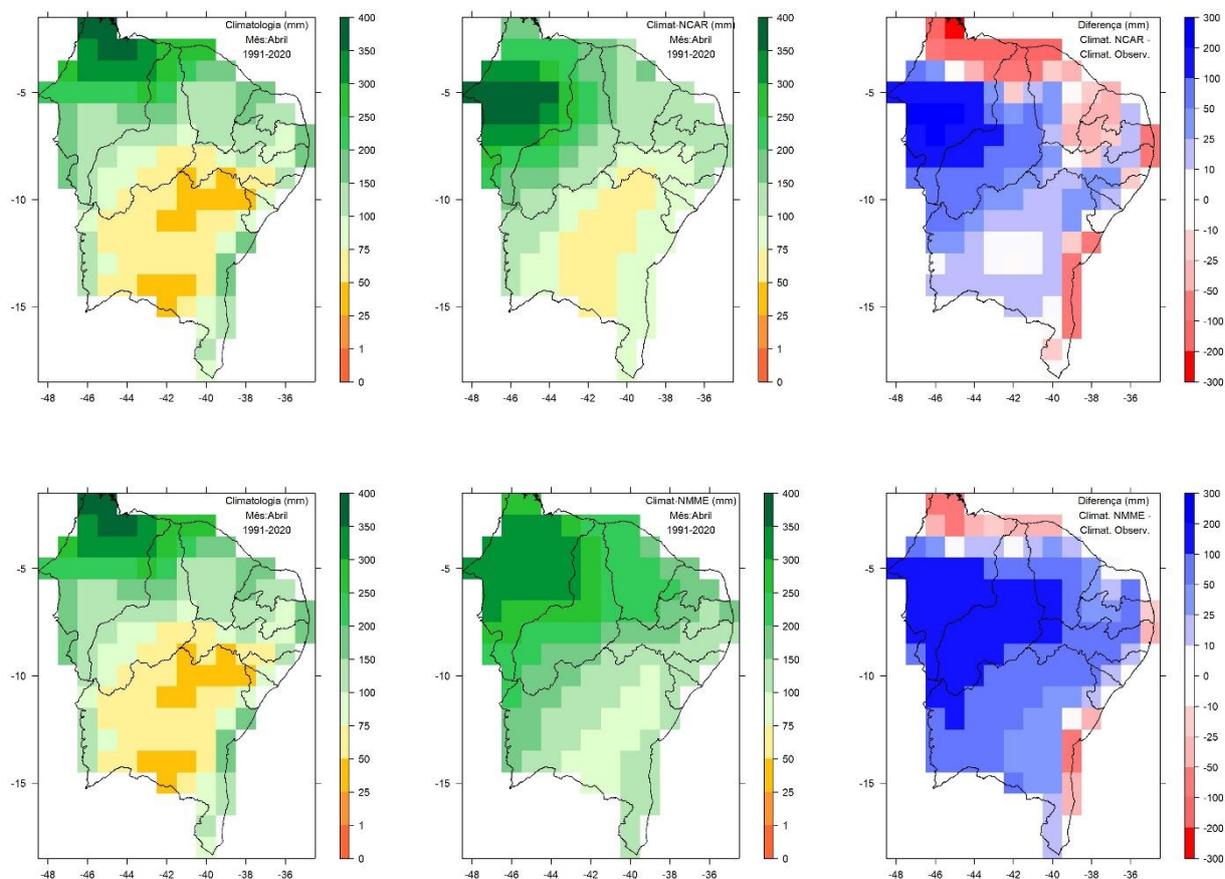
para a necessidade de regionalização (calibração) dos modelos, visando aprimorar a precisão das previsões climáticas nesta área específica.

Já sabe-se que os cenários de mudanças climáticas apontam para uma redução significativa da precipitação pluviométrica de março a maio no norte do Nordeste, de abril a junho no leste do Nordeste, e de outubro a fevereiro no oeste da região. Esses meses coincidem com o período chuvoso destes setores específicos da região Nordeste indicando uma projeção de acentuado déficit de chuvas acumulada anual para a região até o final do século. (COSTA, *et al.*, 2021).

Figura 8 - Painel de comparação das climatologias de Xavier (observada) e bruta dos modelos para o mês de abril no período de 1991 a 2020.







Fonte: Autor, 2023

4.3 Calibração dos modelos com ACC

Foi documentado que modelos dinâmicos apresentam aptidão para fornecer previsões sazonais mais precisas do que a climatologia, especialmente em regiões tropicais (STOCKDALE *et al.*, 1998). Entretanto, estudos também demonstraram que a habilidade de previsão de precipitação pode ser aprimorada por meio da aplicação de técnicas estatísticas para corrigir os resultados do modelo bruto.

Os modelos climáticos regionais exibem competência na previsão de anomalias em torno de valores médios, contudo, revelam desvios relativamente elevados que requerem correção. Essa necessidade de correção é essencial para a utilização apropriada desses resultados na previsão climática (WANG *et al.*, 2004; WOOD *et al.*, 2002; LEUNG *et al.*, 1999).

Diversos erros podem ser corrigidos por meio de abordagens estatísticas que procuram realizar uma análise dos erros com base em séries temporais de dados

observados e modelados. Steed, R. C. e Mass (2004) elucidaram e compararam diversos métodos para a eliminação de erros sistemáticos em modelos de previsão climática. Cada um desses métodos adota uma definição estatística de viés como sendo a discrepância média de um parâmetro.

Métodos de correção estatística são capazes de mitigar as deficiências do modelo ao incorporar detalhes de grande escala com padrões identificados na natureza. Essas abordagens têm sido empregadas para corrigir as anomalias de precipitação no modelo simulado (SMITH E LIVEZEY, 1999; FEDDERSEN *et al.*, 1999) e em previsões sazonais (MO E STRAUS, 2002).

No presente estudo, analisamos os ganhos de precisão das previsões dos modelos climáticos após a calibração com a técnica de Análise de Correlações Canônicas (ACC), usando como referência o índice estatístico de correlação. A legenda das imagens representa a significância estatística das correlações para o período de 30 anos: tons 'azuis' indicam áreas com correlações de 0,3 ou mais, consideradas estatisticamente correlativas, refletindo dados confiáveis para previsões dos modelos.

Para o modelo CFSV2, os dados brutos exibem correlações majoritariamente baixas, com exceções limitadas no extremo norte e sudoeste do Maranhão e sudeste da Bahia (0,3 a 0,4). Após a calibração, observa-se uma melhora substancial, com as correlações anteriormente abaixo de 0,3 agora variando de 0,3 a 0,7, indicando melhorias significativas nas previsões. A região sudeste da Bahia, que já apresentava melhor correlação, avança para 0,7 a 0,8, reforçando a confiabilidade desses dados.

O modelo CMC1 mostra, em sua forma bruta, áreas com correlações baixas no interior do NEB e correlações acima de 0,3 no norte, nordeste e leste, destacando-se o norte do Maranhão com correlações de 0,7 a 0,8. Após a calibração, há melhorias significativas, exceto na porção leste do NEB (BA, SE, AL e PE), onde as correlações permaneceram abaixo de 0,3, indicando dados menos confiáveis mesmo após a aplicação com ACC. O modelo CMC2 exibe correlações muito baixas em sua forma bruta, principalmente na porção leste do NEB, incluindo a Bahia. Após a calibração, há melhorias significativas em toda a região, especialmente na faixa de 0,7 a 0,8 na divisa dos estados do Maranhão e Piauí.

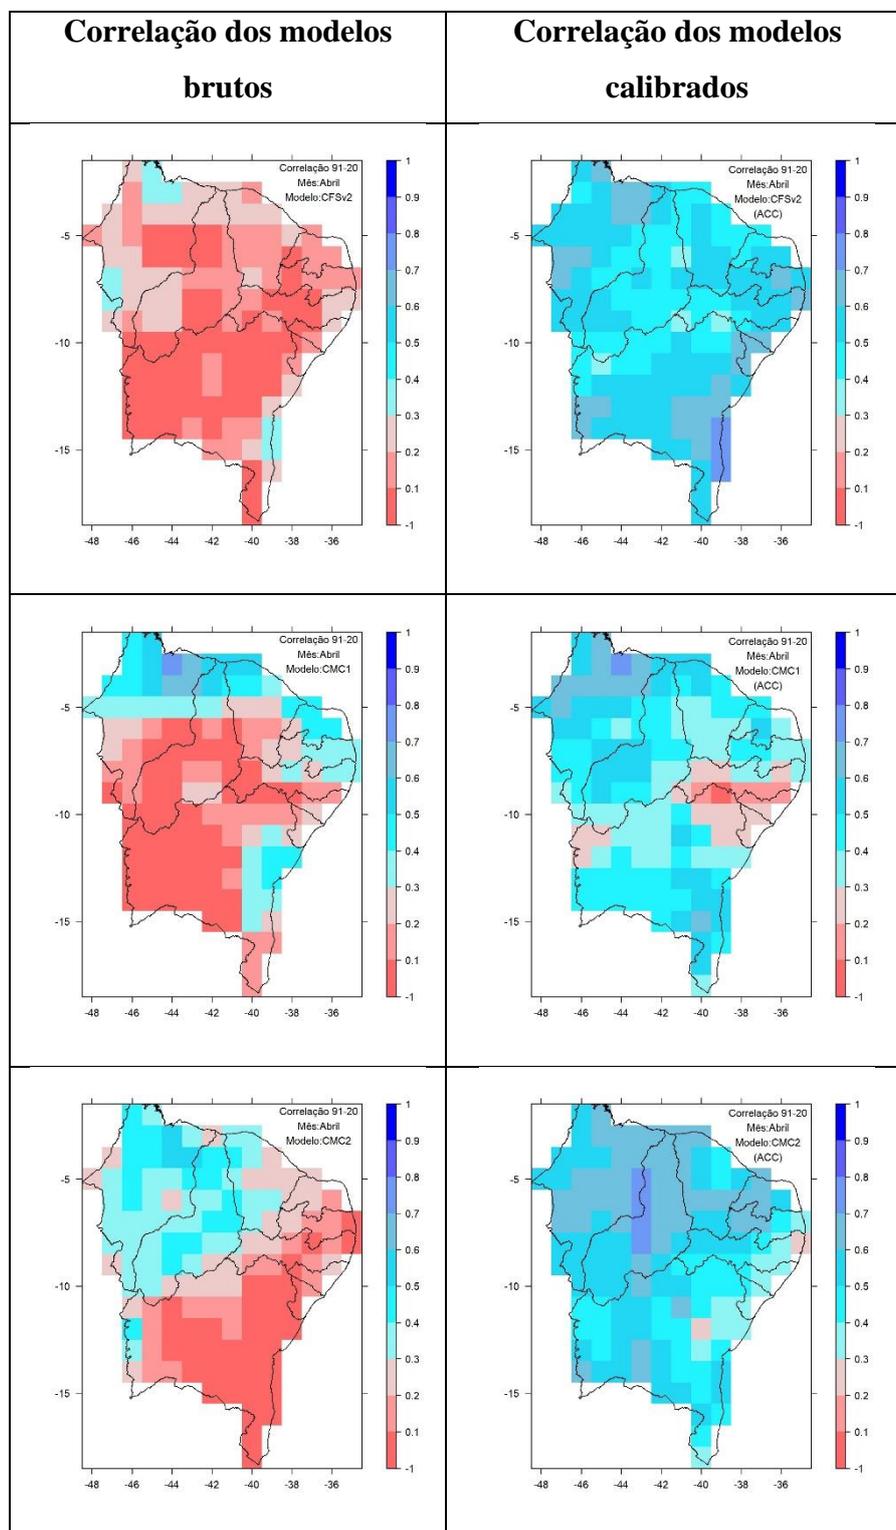
O modelo GFDL apresenta correlações mais altas apenas no extremo norte e nordeste do NEB, enquanto o restante da região exibe correlações abaixo de 0,3. Após a

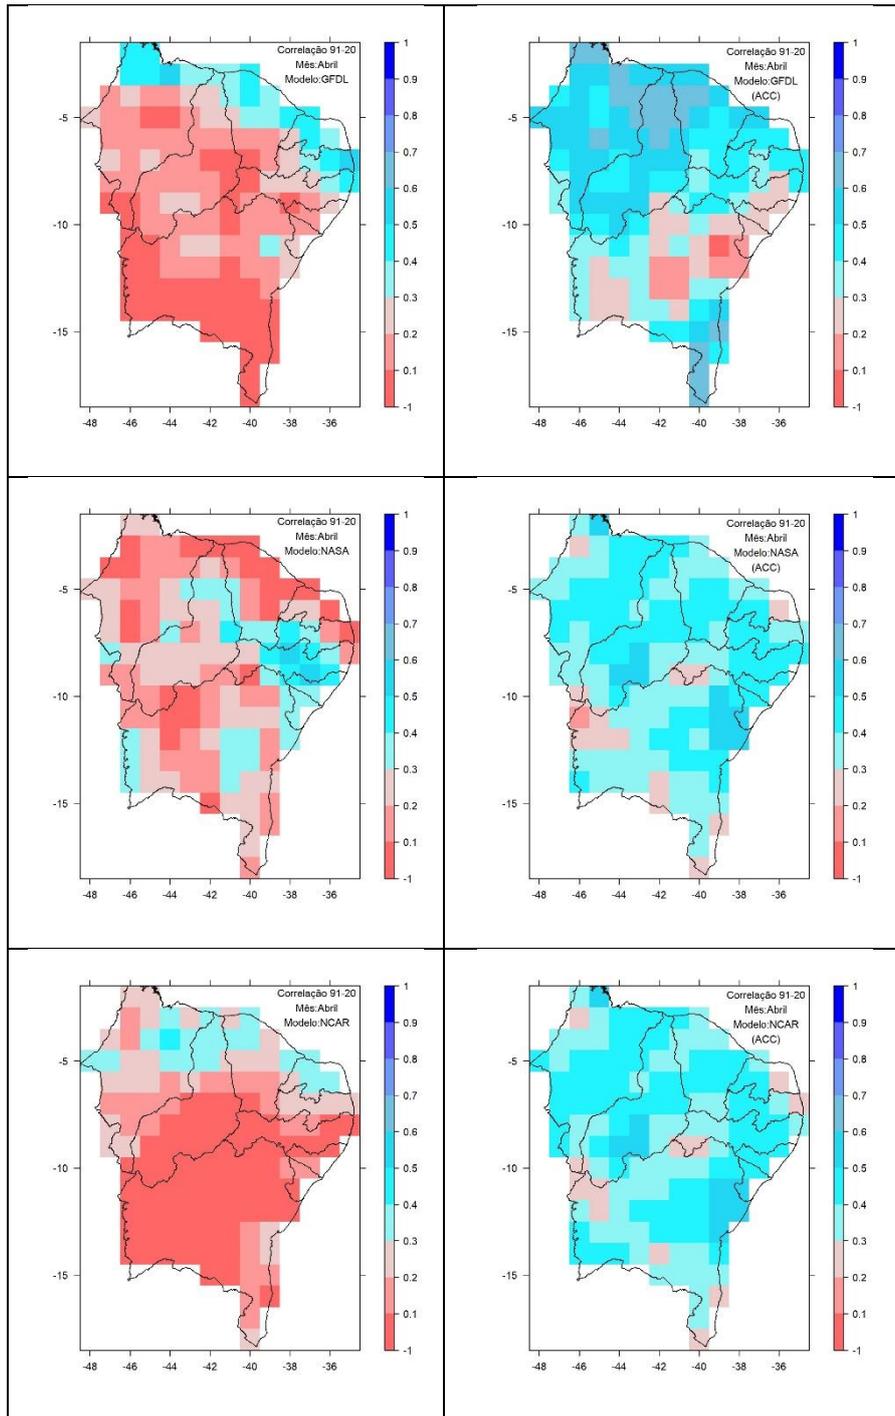
calibração, há melhorias em todo o quadrante de baixas correlações, com exceções em alguns pontos na Bahia, Sergipe, Alagoas e Pernambuco. Destaca-se uma significativa melhoria no extremo sul da Bahia, alcançando valores entre 0,6 a 0,7. O modelo NASA mostra correlações dispersas na forma bruta, com pequenas áreas acima de 0,3 em todos os estados. Após a calibração, há melhorias substanciais em todo o modelo.

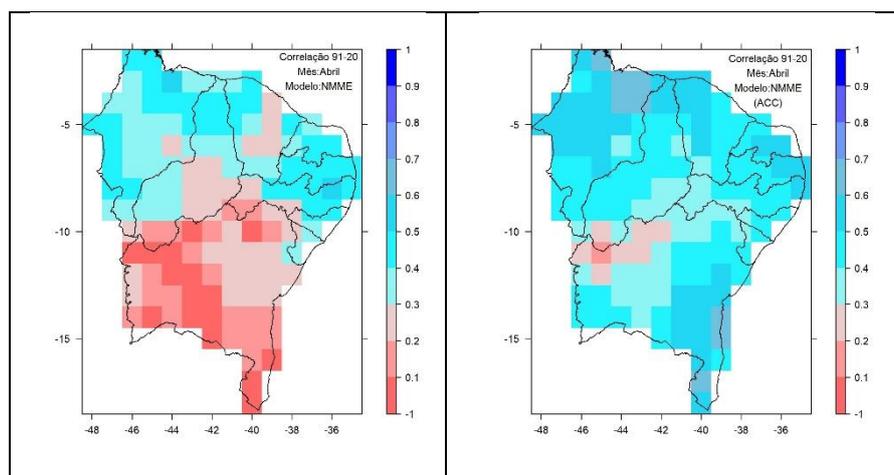
O modelo NCAR exibe correlações baixas na forma bruta em grande parte do NEB, com exceção de alguns pontos ao norte (MA, PI, CE e RN). Após a calibração, há melhorias significativas em toda a região nordeste, especialmente onde as correlações eram extremamente baixas. O modelo NMME revela uma distinção clara entre o norte e sul do NEB, com correlações acima de 0,3 no norte e correlações baixas (entre 0,3 e -1) no sul, especialmente na Bahia. Após a calibração, há melhorias gerais em toda a região, exceto no noroeste da Bahia, onde as correlações permaneceram abaixo de 0,3.

Em resumo, a calibração dos modelos através da ACC resulta em melhorias consideráveis nas previsões em comparação com os dados observados de Xavier ao longo dos 30 anos analisados. Esses resultados evidenciam a importância fundamental de aplicar técnicas estatísticas para previsões climáticas, aumentando substancialmente a confiabilidade dos dados em praticamente todo o NEB.

Figura 9 – Painel comparativo de correlação com os dados de Xavier (1991 a 2020), coluna da esquerda são os modelos brutos e coluna da direita os modelos calibrados com ACC.







Fonte: Autor, 2023

4.4 Matrizes de correlação com técnica ACC

Este segmento do trabalho, tem por objetivo verificar se há algum padrão sistemático de que as melhores previsões ocorrem sempre no lag 1, o que é exatamente no mês anterior ao previsto, avaliando essa possibilidade e também analisando de que outras formas podem-se combinar as previsões entre os lags afim de gerar melhores resultados.

Nas matrizes de correlação global a seguir já foi aplicado a técnica de ACC e, portanto, analisamos os dados reais de cada município e de cada modelo NMME dentro do NEB. A Figura 10 mostra o painel das correlações mensais para cada modelo calibrado e para cada lag, sendo o dado observado da base de Xavier.

É deste painel de correlação global que conseguimos através da média, averiguar em quantos meses o lag 1, lag 2 e lag 3 apresentou melhor performance, como destacado na Tabela 3, onde observamos que o lag 1, que se refere ao mês anterior ao da previsão (exemplo, a previsão para janeiro possui lag1 – dezembro), teve a melhor performance em 6 meses do ano, ou seja, 50% do ano a melhor previsão foi feita exatamente no mês anterior ao da previsão, são eles, fevereiro, março, abril, maio, agosto e setembro, seguido do lag 3 com 4 meses, sendo eles janeiro, junho, julho e dezembro e lag 2 com 2 meses, outubro e novembro.

Outro resultado obtido pelas matrizes de correlações, nos revela um ranking em relação aos modelos do NMME que obtiveram maior participação entre os 3 maiores valores de correlação global. A Tabela 4 mostra que os 2 modelos de maior participação foi o CMC2 e o NCAR com 20 posições, seguido do GFDL com 17 e CMC1 com 16.

Vale destacar que para o estudo em questão não utilizamos o NMME como apenas uma composição dos demais, mas sim como um dos modelos analisados, pois sabendo disso, esperava-se mais participações, porém notamos que independente de usarmos o NMME, o NCAR e o CMC2 se saiu melhor para as previsões do NEB pois obtiveram maior participação no ranking.

Ainda nesse contexto das matrizes, encontramos outra resultante que é os ensembles, verificado na Tabela 6, onde foi extraído da correlação global para cada mês do ano os 3 maiores valores de cada lag, exemplo, para março nós temos no lag1, que são aquelas realizadas em fevereiro, o CMC1, CMC2 e NCAR com os maiores valores de correlação, portanto é realizado uma média dos 3 modelos comparada a observação de março e se obtêm a correlação desse ensemble com valor de 0,64, faz-se a seguinte análise, se esse valor de correlação é maior do que cada modelo que o compôs então mostramos que dá pra fazer combinações com as 3 melhores performances e aumentar a correlação geral de cada modelo individual e isso é observado em todas as situações.

Na sequência também foi calculado o ensemble dos 3 lags, coluna laranja da Tabela 5, basicamente é a combinação dos 3 melhores modelos que saíram no lag 1, no lag 2 e no lag 3, ou seja, é a combinação de 9 resultados. Exemplo, a melhor previsão para março utilizou os modelos CMC1, CMC2 e NCAR rodado em fevereiro (lag 1), para a rodada em janeiro (lag 2) utilizou os modelos CMC2, GFDL e NASA, e para o lag 3 que é rodado em dezembro utilizou os modelos CMC1, NASA e NCAR, gerando um resultado de 0,76, dessa forma tendemos a melhorar a performance histórica dos resultados em relação a observação, aumentando a confiança na previsão.

Portanto, quando usamos de técnicas estatísticas, como ACC utilizada neste estudo, calibramos os modelos e confrontamos diretamente com a realidade (dados observados) melhoramos significativamente a performance e estabelecemos novas metodologias que possibilitem previsões mais confiáveis para o Nordeste Brasileiro.

Figura 10 - Painel de correlação global mensal dos modelos calibrados

Correlação Global - Janeiro			
Modelo	Lag 1	Lag 2	Lag 3
CFSv2	0,36	0,63	0,38
CMC1	0,31	0,30	0,50
CMC2	0,38	0,23	0,22
GFDL	0,44	0,12	0,53
NASA	0,36	0,28	0,33
NCAR	0,27	0,62	0,29
NMME	0,37	0,46	0,40
Média	0,36	0,38	0,38

Correlação Global - Fevereiro			
Modelo	Lag 1	Lag 2	Lag 3
CFSv2	0,41	0,39	0,33
CMC1	0,41	0,48	0,26
CMC2	0,59	0,25	0,19
GFDL	0,56	0,56	0,37
NASA	0,46	0,58	0,16
NCAR	0,26	0,18	0,20
NMME	0,45	0,40	0,25
Média	0,45	0,41	0,25

Correlação Global - Março			
Modelo	Lag 1	Lag 2	Lag 3
CFSv2	0,34	0,35	0,29
CMC1	0,56	0,31	0,58
CMC2	0,49	0,46	0,36
GFDL	0,45	0,50	0,24
NASA	0,28	0,47	0,40
NCAR	0,46	0,36	0,45
NMME	0,41	0,34	0,33
Média	0,43	0,40	0,38

Correlação Global - Abril			
Modelo	Lag 1	Lag 2	Lag 3
CFSv2	0,42	0,36	0,55
CMC1	0,61	0,47	0,52
CMC2	0,49	0,49	0,45
GFDL	0,38	0,46	0,40
NASA	0,46	0,29	0,44
NCAR	0,48	0,45	0,38
NMME	0,60	0,44	0,45
Média	0,49	0,42	0,46

Correlação Global - Maio			
Modelo	Lag 1	Lag 2	Lag 3
CFSv2	0,57	0,27	0,20
CMC1	0,46	0,48	0,45
CMC2	0,46	0,52	0,57
GFDL	0,34	0,36	0,33
NASA	0,65	0,44	0,51
NCAR	0,53	0,51	0,45
NMME	0,51	0,52	0,64
Média	0,50	0,44	0,45

Correlação Global - Junho			
Modelo	Lag 1	Lag 2	Lag 3
CFSv2	0,46	0,35	0,41
CMC1	0,48	0,53	0,29
CMC2	0,48	0,26	0,49
GFDL	0,40	0,54	0,55
NASA	0,48	0,43	0,42
NCAR	0,43	0,45	0,53
NMME	0,31	0,46	0,44
Média	0,43	0,43	0,45

Correlação Global - Julho			
Modelo	Lag 1	Lag 2	Lag 3
CFSv2	0,18	0,37	0,54
CMC1	0,42	0,14	0,21
CMC2	0,38	0,30	0,33
GFDL	0,51	0,43	0,26
NASA	0,31	0,42	0,32
NCAR	0,39	0,28	0,47
NMME	0,17	0,42	0,31
Média	0,34	0,34	0,35

Correlação Global - Agosto			
Modelo	Lag 1	Lag 2	Lag 3
CFSv2	0,46	0,34	0,58
CMC1	0,39	0,47	0,45
CMC2	0,52	0,44	0,51
GFDL	0,51	0,16	0,47
NASA	0,45	0,45	0,38
NCAR	0,32	0,53	0,47
NMME	0,57	0,38	0,37
Média	0,46	0,40	0,46

Correlação Global - Setembro			
Modelo	Lag 1	Lag 2	Lag 3
CFSv2	0,29	0,26	0,34
CMC1	0,38	0,33	0,23
CMC2	0,46	0,35	0,33
GFDL	0,51	0,48	0,09
NASA	0,37	0,20	0,26
NCAR	0,54	0,38	0,48
NMME	0,39	0,20	0,26
Média	0,42	0,31	0,28

Correlação Global - Outubro			
Modelo	Lag 1	Lag 2	Lag 3
CFSv2	0,31	0,47	0,49
CMC1	0,59	0,45	0,31
CMC2	0,44	0,38	0,43
GFDL	0,28	0,43	0,33
NASA	0,37	0,50	0,47
NCAR	0,40	0,49	0,50
NMME	0,32	0,43	0,48
Média	0,39	0,45	0,43

Correlação Global - Novembro			
Modelo	Lag 1	Lag 2	Lag 3
CFSv2	0,31	0,58	0,22
CMC1	0,42	0,37	0,40
CMC2	0,38	0,40	0,33
GFDL	0,29	0,31	0,21
NASA	0,31	0,39	0,37
NCAR	0,36	0,46	0,40
NMME	0,34	0,38	0,41
Média	0,34	0,41	0,33

Correlação Global - Dezembro			
Modelo	Lag 1	Lag 2	Lag 3
CFSv2	0,30	0,46	0,56
CMC1	0,40	0,27	0,43
CMC2	0,38	0,24	0,35
GFDL	0,48	0,40	0,49
NASA	0,30	0,26	0,53
NCAR	0,30	0,49	0,48
NMME	0,40	0,39	0,35
Média	0,37	0,36	0,46

Fonte: Autor, 2023

Tabela 3 - Meses do ano x Melhor lag de previsão

Meses do ano	Melhor previsão
Janeiro	Lag 3
Fevereiro	Lag 1
Março	Lag 1
Abril	Lag 1
Maio	Lag 1
Junho	Lag 3
Julho	Lag 3
Agosto	Lag 1
Setembro	Lag 1
Outubro	Lag 2
Novembro	Lag 2
Dezembro	Lag 3

Fonte: Autor, 2023

Tabela 4 - Participação de cada modelo nas 3 maiores correlações

Modelo	Participação entre os três de maior correlação
CFSv2	12
CMC1	16
CMC2	20
GFDL	17
NASA	11
NCAR	20
NMME	12

Fonte: Autor, 2023

Tabela 5 - Correlação dos Ensembles

Correlação dos ensembles				
Mês	Lag 1	Lag 2	Lag 3	Lag1+Lag2+Lag3
Janeiro	0,49	0,73	0,63	0,71
Fevereiro	0,69	0,68	0,44	0,72
Março	0,64	0,65	0,65	0,7631
Abril	0,63	0,56	0,60	0,66
Maio	0,69	0,62	0,70	0,7626
Junho	0,61	0,65	0,68	0,75
Julho	0,61	0,56	0,60	0,72
Agosto	0,63	0,62	0,68	0,74
Setembro	0,64	0,55	0,55	0,68
Outubro	0,65	0,64	0,61	0,7549
Novembro	0,56	0,65	0,52	0,65
Dezembro	0,52	0,60	0,66	0,72

Fonte: Autor, 2023

5. CONCLUSÕES

O Nordeste brasileiro é suscetível às variações climáticas, uma vez que apresenta longos períodos de escassez de água devido às secas. Neste estudo abordamos esse cenário afim de avaliar os vieses das previsões brutas de precipitação do NMME e examinar as melhorias com o pós-processamento por meio do método ACC. Para mostrar a confiabilidade dos dados de análise gradeada de Xavier foram usadas 96 estações meteorológicas convencionais do INMET afim de compará-las. Nesse ponto percebeu-se a forte coerência entre as climatologias indicando assim a confiabilidade dos dados de Xavier devido a sua eficiência na representação da precipitação acumulada mensal.

Os dados de Xavier tendem a subestimar a precipitação na maior parte do Nordeste, com variações de 5 a 25 mm em diferentes regiões. Os índices de verificação, como o viés e a correlação média mensal, confirmam essa tendência. Os erros de Xavier são geralmente baixos em relação às observações, com máximos de 25 a 50 mm em algumas áreas.

A avaliação de modelos NMME para a previsão de abril, iniciando em janeiro, comparou as climatologias brutas dos sete modelos com as observações reais de Xavier. O modelo CFSV2 mostrou uma tendência acentuada de subestimar a precipitação no NEB, enquanto CMC1 e CMC2 também subestimaram no leste, norte e noroeste, mas superestimaram no interior. Por outro lado, o modelo GFDL superestimou em quase todo o NEB, exceto no extremo leste da Bahia. O modelo da NASA também superestimou em todo o NEB, com diferenças de até 400mm em relação a Xavier. O modelo NCAR foi o mais próximo das observações, mostrando mais áreas neutras. Já o NMME tende a superestimar o NEB, com destaque para o noroeste do Maranhão e Piauí.

São essas discrepâncias que oferecem justificativas sólidas na necessidade de regionalizar (calibrar) os modelos, afim de aprimorar a precisão das previsões climáticas. Os resultados pós processamento usando como referência o índice estatístico de correlação mostrou melhorias consideráveis nas previsões ao longo dos 30 anos analisados, uma vez que, valores de 0,3 ou mais representam significância estatisticamente relevante.

Outrossim, avaliamos as matrizes de correlação global dos modelos e seus respectivos lags para averiguar melhor performance, notou-se que o lag 1 teve melhor

desempenho em 6 meses do ano, ou seja, 50% do ano a melhor previsão foi feita exatamente no mês anterior ao da previsão, seguido do lag 3 com 4 meses e lag 2 com 2 meses. Estruturamos um ranking dos modelos NMME que obtiveram maior participação entre os 3 maiores valores de correlação global sendo CMC2 e NCAR com 20 posições, seguido do GFDL com 17 e CMC1 com 16. Nota-se que independente de usarmos o NMME como um dos modelos analisados, o NCAR e o CMC2 obtiveram melhores previsões do NEB pois sua participação no ranking foi maior. Outra resultante é os ensembles onde pôde-se observar que o valor da correlação é maior do que cada modelo que o compôs, constatou-se então que é possível fazer combinações com as 3 melhores performances e aumentar a correlação geral de cada modelo individual e isso foi observado em todas as situações. Por fim calculamos o ensemble dos 3 lags para cada mês, essa avaliação evidenciou que a combinação dos 3 melhores modelos em cada lag, ou seja, a combinação de 9 resultados tende a melhorar a performance histórica, aumentando a confiança na previsão.

Diante dos resultados apresentados, a pesquisa visou verificar os vieses das previsões brutas da precipitação acumulada mensal do NMME e a melhoria desta após pós-processamento com ACC para o NEB, sendo assim, foram elencados por meio de figuras e tabelas as comparações desta avaliação sendo base de justificativa a importância de calibrar os dados do modelo para previsões mais assertivas.

A dissertação valida a abordagem de comparar as previsões dos modelos com as observações reais. Embora se esperasse que as previsões para um determinado mês, iniciadas em meses anteriores, refletissem com precisão o clima histórico, houve discrepâncias nas previsões iniciadas em janeiro para abril, bem como nas previsões iniciadas em fevereiro e março. Ou seja, a aproximação do mês de previsão não garantiu uma melhoria consistente. Isso é evidenciado pelo fato de que o lag 3 (três meses antes da previsão) apresentou mais casos de melhorias do que o lag 2, enquanto o lag 1 se destacou em 6 meses do ano, mas não em todos. Portanto, embora o lag 1 seja significativo, ele não é definitivo em todas as situações.

REFERÊNCIAS BIBLIOGRÁFICAS

AHMADALIPOUR, A.; RANA, A.; MORADKHANI, H.; SHARMA, A. Multi-criteria evaluation of CMIP5 GCMs for climate change impact analysis. **Theoretical and Applied Climatology**, v. 128, n. 1, p. 71-87, 2017.

AL-ACHI, A. The student's t-test: a brief description. **Research & Reviews: Journal of Hospital and Clinical Pharmacy**, v. 5, n. 1, p. 1, 2019.

ALEXANDER, M.; BLADE, I.; NEWMAN, M.; LANZANTE, J.; LAU, N.; SCOTT, J. The atmospheric bridge: the influence of ENSO teleconnections on air-sea interaction over the global oceans. **Journal of Climate**, v. 15, n. 16, p. 2205- 2229, 2002.

AL ZAWAD, F.M.; AKSAKAL, A. Impacts of climate change on water resources in Saudi Arabia. **In Global Warming**, p. 511-523, 2010.

ANDERSON, D.T.; SARACHIK, E.S.; WEBSTER, P.J.; ROTHSTEIN, L.M. The TOGA decade: Reviewing the progress of El Niño research and prediction. **Journal of geophysical research**, v. 103, n. C7, 1998.

ANDERSON, M. C.; ZOLIN, C. A.; HAIN, C. R.; SEMMENS, K.; YILMAZ, M. T.; GAO, F. Comparison of satellite-derived LAI and precipitation anomalies over Brazil with a thermal infrared-based Evaporative Stress Index for 2003–2013. In: **Journal of Hydrology**, 526, 287-302, 2015.

ANJOS, M.; LOPES, A. Sea breeze front identification on the northeastern coast of Brazil and its implications for meteorological conditions in the Sergipe region. **Theoretical and Applied Climatology**, v. 137, p. 2151–2165, 2019.

ARAÚJO COSTA, DE J. O fenômeno El Niño e as secas no Nordeste do Brasil. 2014.

BARNETT, T.P.; GRAHAM, N.; LATIF, M.; PAZAN, S.; WHITE, W. ENSO and ENSO-related predictability. Part I: Prediction of equatorial Pacific sea surface temperature with a hybrid coupled ocean–atmosphere model. **Journal Climate** 6, p. 1545–1566, 1993.

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.1825-1849, 1987.

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

BARNSTON, A.G.; ROPELEWSKI, C.F. Prediction of ENSO episodes using canonical correlation analysis. **Journal of Climate**, v. 5, n. 11, p. 1316-1345, 1992.

BARNSTON, A.G.; LIVEZEY R.E. Classification, seasonality and persistence of low-frequency atmospheric circulation patterns. **Monthly Weather Review**, v. 11, p. 1083–1126, 1987.

BARNSTON, A.G.; TIPPETT, M.K. Do statistical pattern corrections improve seasonal climate predictions in the North American Multimodel Ensemble models. **Journal of Climate**, v. 30, n. 20, p. 8335-8355, 2017.

BARNSTON, A.G, Y. HE, AND M. H. GLANTZ, 1999A: Predictive skill of statistical and dynamical climate models in forecasts of SST during the 1997-98 El Nino episode and the 1998 La Nina onset. *J. Climate*, 12,217-244

BAUER, P.; THORPE, A.; BRUNET, G. The quiet revolution of numerical weather prediction. **Nature**, v. 525, n. 7567, p. 47-55, 2015.

BECKER, E.; KIRTMAN, B.P.; PEGION, K. Evolution of the North American Multi-Model Ensemble. **Geophysical Research Letters**, v. 47, n. 9, 2020.

BECKER, E.J.; VAN DEN DOOL, H.; PEÑA, M. M. Extremos climáticos de curto prazo: habilidade de previsão e previsibilidade. **Jornal do clima**, v. 26, n. 2, p. 512-531, 2013.

BJERKNES, J. Atmospheric teleconnections from the equatorial Pacific. **Monthly Weather Review**, v.97, p. 163-172, 1969.

BJERKNES, J. A possible response of the atmospheric Hadley circulation to equatorial anomalies of ocean temperature. **Tellus**, v. 18, p. 820-829, 1966.

BLANFORD, H.F. On the connexion of the Himalayan snow with dry winds and seasons of droughts in India. **Proceedings of the Royal Society of London**, v.37, p. 3-22, 1884.

BENESTAD, R. E.; CHEN, D.; MEZGHANI, A.; FAN, L.; PARDING, K. On using principal components to represent stations in empirical–statistical downscaling. **Tellus A: Dynamic Meteorology and Oceanography**, v. 67, n. 1, p. 28326, 2015.

BONAVITA, M.; HÓLM, E.; ISAKSEN, L.; FISHER, M. The evolution of the ECMWF hybrid data assimilation system. **Quarterly Journal of the Royal Meteorological Society**, v, 142, n. 694, p. 287-303, 2016.

BRAHMANANDA, R.V.; DE LIMA, M.C.; FRANCHITO, S.H. Seasonal and interannual variations of rainfall over eastern northeast Brazil. **Journal of climate**, v. 6, n. 9, p. 1754-1763, 1993.

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: A Journal of the Royal Meteorological Society**, v. 28, n. 4, p. 449-464, 2008.

CARVALHO, L.M.V. Assessing precipitation trends in the Americas with historical data: A review. **WIREs Climate Change**, v. 11, p. e627, 2020.

CARVALHO, M.A.V.D.; 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.

CAVALCANTE, L.C.V.; FEDOROVA, N.; LEVIT, V. Influência dos Distúrbios Tropicais na Formação de Fenômenos Adversos de Atmosfera Estável no Nordeste Brasileiro. **Revista Brasileira de Meteorologia**, v. 35, p. 735-743, 2020.

CAVALCANTI, I.F.A. Large scale and synoptic features associated with extreme precipitation over South America: A review and case studies for the first decade of the 21st century. **Atmospheric Research**, v. 118, p. 27-40, 2012.

CIRILO, J.A. Integração das águas superficiais e subterrâneas. In: CIRILO, J. A. et al. (Org.) O uso sustentável dos recursos hídricos em regiões semi-áridas. **Recife: ABRH - Editora Universitária UFPE**, p. 508, 2007.

CGEE e Agência Nacional de Águas - ANA (2012). A Questão da Água no Nordeste. Brasília, DF.

CHANG, P.; GIESE, B.S.; JI, L.; SEIDEL, H.F. Decadal Change in the South Tropical Pacific in a Global Assimilation Analysis, **Geophysical Research Letters**, v. 28, p. 3461–3464, 2001.

CHARNEY, J.G.; SHUKLA J. Predictability of monsoons. Monsoon Dynamics, Editors: Sir James Lighthill and R.P. Pearce, **Cambridge University Press**, p. 99–109, 1981.

CHOWDHURY, M.R.; CHU, P.S.; SCHROEDER, T. ENSO e variabilidade sazonal do nível do mar – uma discussão diagnóstica para as ilhas do Pacífico afiliadas aos EUA. **Climatologia Teórica e Aplicada**, v. 88, n. 3, pág. 213-224, 2007.

CHU, P.S.; HE, Y. Long-range prediction of Hawaiian winter rainfall using canonical correlation analysis. **International Journal of Climatology**, v. 14, n. 6, p. 659-669, 1994.

CHU, S. Nobel Lecture: The manipulation of neutral particles. **Reviews of Modern Physics**, v. 70, n. 3, p. 685, 1998.

CLARK, M.P.; SLATER, A.G. Probabilistic quantitative precipitation estimation in complex terrain. **Journal of Hydrometeorology**, v. 7, n. 1, p. 3-22, 2006.

COELHO, C.A.S.; STEPHENSON, D.B.; DOBLAS-REYES, F.J.; BALMASEDA M.; GUETTER, A.; VAN OLDENBORGH, G.J.A Bayesian approach for multi-model downscaling: Seasonal forecasting of regional rainfall and river flows in South America. **Meteorological Applications**, v. 13, n. 1, p. 73-82, 2006.

COELHO, C.A.; STEPHENSON, D.B.; DOBLAS-REYES, F.J.; BALMASEDA, M.; GRAHAM, R. Integrated seasonal climate forecasts for South America. **CLIVAR Exchanges**, v. 12, p. 13-19, 2007.

COLLINS, D.C. Assessment of ensemble regression to combine and weight seasonal forecasts from multiple models of the NMME. In **Climate prediction S&T digest: NWS science & technology infusion climate bulletin supplement**. Chapter Climate prediction S&T digest: National Oceanic Atmospheric Administration. Professional Paper, 2017.

COLLINS, D.C.; REASON, C.J.C.; TANGANG, F. Predictability of Indian Ocean sea surface temperature using canonical correlation analysis. **Climate Dynamics**, v. 22, n. 5, p. 481-497, 2004.

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

COSTA, R. L., GOMES, H. B., SILVA, F. D. D. S., BAPTISTA, G. M. D. M., ROCHA JÚNIOR, R. L. D., HERDIES, D. L., SILVA, V. D. P. Cenários de Mudanças Climáticas para a Região Nordeste do Brasil por meio da Técnica de Downscaling Estatístico. **Revista Brasileira de Meteorologia**, v. 35, p. 785-801, 2021.

COSTA, R. L.; SOUZA, E. P. D.; 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, n. 1, p. 96-104, 2014.

CRUZ, C.D.; CARNEIRO, P.C.S. Modelos biométricos aplicados ao melhoramento genético. Viçosa: UFV, 2003.

DA SILVA, P.E.; SANTOS E SILVA, C.M.; SPYRIDES, M.H.C.; ANDRADE, L.M.B. Analysis of climate extreme indices in the Northeast Brazil and the Brazilian Amazon in the period from 1980 to 2013. **Anuário do Instituto de Geociências - UFRJ**, v. 42, n. 2, p. 137-148, 2019.

DA SILVA, P.E.; SILVA, C.M.S.; SPYRIDES, M.H.C.; ANDRADE, L.M.B. Precipitation and air temperature extremes in the Amazon and northeast Brazil. **International Journal of Climatology**, v. 39, n. 2, p. 1-17, 2018.

DA SILVA, J. W., SOARES, L., FERREIRA, P. V., DA SILVA, P. P., & DA SILVA, M. J. C. Correlações canônicas de características agroindustriais em cana-de-açúcar. **Acta Scientiarum. Agronomy**, v. 29, n. 3, p. 345-349, 2007.

DA ROCHA JÚNIOR, R.L.; CAVALCANTE PINTO, D.D.; DOS SANTOS SILVA, F.D.; GOMES, H.B.; BARROS GOMES, H.; COSTA, R.L.; PEREIRA M.P.S.; PENÃ M.; DOS SANTOS COELHO C.A.; HERDIES, D.L. **An Empirical Seasonal Rainfall**

Forecasting Model for the Northeast Region of Brazil. *Water*, v. 13, n. 12, p. 1613, 2021.

DA ROCHA JÚNIOR, R.L.; DOS SANTOS SILVA, F.D.; COSTA, R.L.; GOMES, H.B.; PINTO, D.D.C.; COSTA, R.L.; PEREIRA M.P.S; PENÃ M.; DOS SANTOS COELHO C.A.; HERDIES, D.L. Avaliação bivariada de períodos e frequência de retorno de seca no nordeste brasileiro usando distribuição conjunta pelo método de cópula. **Geociências**, v. 10, n. 4, p. 135, 2020.

DA ROCHA JÚNIOR, R.L.; DOS SANTOS SILVA, F.D.; LISBOA COSTA, R.; BARROS GOMES, H.; HERDIES, D.L.; RODRIGUES DA SILVA, V.D.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, n. 11, p. 457, 2019.

DE BRITTO PEREIRA, Ricardo Vela et al. Utilização de modelagem híbrida wavelet nas previsões de séries temporais como auxílio de compreensão na análise meteorológica, 2016.

DELWORTH, T.L.; BROCCOLI, A.J.; ROSATI, A.; STOUFFER, R.J.; BALAJI, V.; BEESLEY, J.A.; COOKE W.F.; DIXON K.W.; DUNEE J.; DUNNE K.A.; DURACHTA, J.W.; ... ZHANG, R. GFDL's CM2 global coupled climate models. Part I: Formulation and simulation characteristics. **Journal of Climate**, v. 19, n. 5, p. 643-674, 2006.

DE OLIVEIRA, A.M.; DE AMORIM, R.F.; DA SILVA COSTA, D.F. Implicações das oscilações climáticas do Quaternário tardio na evolução da fisionomia da vegetação do semiárido do Nordeste Setentrional. **Revista de Geociências do Nordeste**, v. 4, p. 50-65, 2018.

DEVORE, J. L. Probabilidade e estatística para engenharia e ciências. Cengage Learning, 6ª edição. 2006.

DIAZ, A.F.; STUDZINSKI, C.D.; MECHOSO, C.R. Relationships between precipitation anomalies in Uruguay and southern Brazil and sea surface temperature in the Pacific and Atlantic Oceans. **Journal of Climate**, v. 11, n. 2, p. 251-271, 1998.

DÍAZ, D.; VILLEGAS, N. Canonical correlation between large scale climate oscillations and surface meteorological variables in Colombia. **Revista UDCA Actualidad & Divulgación Científica**, v. 18, n. 2, p. 543-552, 2015.

DOS SANTOS, W.M.; SOUZA, R.M.S.; DE SOUZA, E.S.; DE ALMEIDA, A.Q.; ANTONINO, A.C.D.; Variabilidade espacial da sazonalidade da chuva no semiárido brasileiro. **Journal of Environmental Analysis and Progress**, p. 368-376, 2017.

DROSDOWSKY, Wasyl; CHAMBERS, Lynda E. Near-global sea surface temperature anomalies as predictors of Australian seasonal rainfall. **Journal of Climate**, v. 14, n. 7, p. 1677-1687, 2001.

ESCOBAR, G.C.J. Classificação Sinótica Durante a Estação Chuvosa do Brasil. **Anuário do Instituto de Geociências**, v. 42, n. 2, p. 421-436, 2019.

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

FENTA MEKONNEN, D.; DISSE, M. Analyzing the future climate change of Upper Blue Nile River basin using statistical downscaling techniques. **Hydrology and Earth System Sciences**, v. 22, n.4, p. 2391-2408, 2018.

FEDDERSEN, H.; NAVARRA, A. & WARD, M.N. "Reduction of Model Systematic Error by Statistical Correction for Dynamical Seasonal Predictions", **Journal of Climate**, Vol. 12, July, 1974-1989, 1999.

FUNCEME. Fundação Cearense de Meteorologia e Recursos Hídricos. Sistemas atmosféricos atuantes no Nordeste do Brasil. Disponível em: <http://www.funceme.br/?p=967>. Acesso: 23/02/2022.

GELARO, R.; MCCARTY, W.; SUÁREZ, M.J.; TODLING, R.; MOLOD, A.; TAKACS, L.; ... ZHAO, B. The modern-era retrospective analysis for research and applications, version 2 (MERRA-2). **Journal of climate**, v.30, n.14, p. 5419-5454, 2017.

GLAHN H.R. Canonical correlation analysis and its relationship to discriminant analysis and multiple regression. **Journal of Atmosphere Science**, v. 25, n. 1, p. 23-31, 1968.

GNEITING, T.; RAFTERY, A.E. Weather forecasting with ensemble Methods. **Science**, v. 310, n. 5746, p. 248-249, 2005.

GODDARD, L.; MASON, S.J.; ZEBIAK, S.E.; ROPELEWSKI, C.F.; BASHER, R.; CANE, M.A. Current approaches to seasonal to interannual climate predictions. **A Journal of the Royal Meteorological Society**, v. 21, n.9, p. 1111-1152, 2001.

GOMES, H.B.; AMBRIZZI, T.; HERDIES, D.L.; HODGES, K.; PONTES DA SILVA, B.F. Easterly wave disturbances over Northeast Brazil: an observational analysis. **Advances in Meteorology**, v. 2015, 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.F.B. Climatology of easterly wave disturbances over the tropical South Atlantic. **Climate Dynamics**, v. 53, n. 3, p. 1393-1411, 2019.

GRAHAM, N.E.; MICHAELSEN, J.; BARNETT, T.P. An investigation of the El Niño-Southern Oscillation cycle With statistical models: 1. Predictor field characteristics. **Journal of Geophysical Research: Oceans**, v. 92, n. C13, p. 14251-14270, 1987.

GRAHAM, N.E.; MICHAELSEN, J.; BARNETT, T.P. An investigation of the El Niño-Southern Oscillation cycle With statistical models: 2. Model results. **Journal of Geophysical Research: Oceans**, v. 92, n. C13, p. 14271-14289, 1987.

HASTENRATH, S. Exploring the climate problems of Brazil's Nordeste: a review. **Climatic Change**, v. 112, n. 2, p. 243-251, 2012.

HASTENRATH, S.; WU M.C.; CHU P.S. Towards the monitoring and prediction of north-east Brazil droughts. **Quarterly Journal of the Royal Meteorological Society**, v. 110, n. 464, p. 411-425, 1984.

HASTENRATH, S. Prediction of Northeast Brazil Rainfall Anomalies. **Journal of Climate**, v. 3, p. 893-904, 1990.

HASTENRATH, S.; HELLER, L. Dynamics of climatic hazards in northeast Brazil. **Quarterly Journal of the Royal Meteorological Society**, v. 103, n. 435, p. 77-92, 1977.

HASTENRATH, S.; HELLER, L. Dynamic of Climate Hazards in Northeast Brasil. **Quarterly Journal of Royal Meteorological Society**, v. 42, p. 129-151, 2006.

HASTENRATH, S. On Modes of Tropical Circulation and Climate Anomalies. In: **Journal of the Atmospheric Sciences**, v. 35, p. 2222-2231, 1978.

HASTENRATH, S.; SUN, L.; MOURA, A.D. Climate prediction for Brazil's Nordeste by empirical and numerical modeling methods. **International Journal of Climatology**, v. 29, n. 6, p. 921-926, 2009.

HATTERMANN, F.; KRYSANOVA, V.; GOSLING, S.N.; DANKERS, R.; DAGGUPATI, P.; DONNELLY, C.; FLÖRKE, M.; HUANG, S.; MOTOVILOV, Y.; BUDA, S. Cross- scale intercomparison of climate change impacts simulated by regional and global hydrological models in eleven large river basins. **Climatic Change**, v.141, n.3, p. 561-576, 2017.

HELD, I.M.; GUO, H.; ADCROFT, A.; DUNNE, J.P.; HOROWITZ, L.W.; KRASTING, J.; ... ZADEH N. Structure and performance of GFDL's CM4. climate model. **Journal of Advances in Modeling Earth Systems**, v. 11, n. 11, p. 3691-3727, 2019.

HERDIES, D. L. et al. Evaluation of Surface Data Simulation Performance with the Brazilian Global Atmospheric Model (BAM). **Atmosphere**, v. 14, n. 1, p. 125, 6 jan. 2023.

HOREL, J.D.; WALLACE, J.M. Planetary-scale atmospheric phenomena associated with the Southern Oscillation. **Monthly Weather Review**, v. 109, n. 4, p. 813-829, 1981.

HOSKINS, B. The potential for skill across the range of the seamless weather-climate prediction problem: a stimulus for our science. **Quarterly Journal of the Royal Meteorological Society**, v. 139, n. 672, p. 573-584, 2013.

HOTELLING, H. Relations between two sets of variates. **Breakthroughs in statistics**. Springer, New York, NY, p. 162-190, 1992.

INFANTI, J.M.; KIRTMAN, B.P. Prediction and predictability of land and atmosphere initialized CCSM4 climate forecasts over North America. **Journal of Geophysical Research: Atmospheres**, v. 121, n. 21, p. 12690-12701, 2016.

IPCC (The Intergovernmental Panel on Climate Change) (2018) Special Report Warming of 1.5°C. Disponível em: <https://www.ipcc.ch/sr15/>. Acesso: 06/03/2022.

IPCC. Summary for Policymakers. In: *Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change* [Solomon, S., D. Qin, M. Manning, Z. Chen, M. Marquis, K.B. Averyt, M. Tignor and H.L. Miller (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 2007.

IPCC. *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* [Stocker, T.F., D. Qin, G.-K. Plattner, M. Tignor, S.K. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex and P.M. Midgley (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1535 p, 2013.

IRI - INTERNATIONAL RESEARCH INSTITUTE FOR CLIMATE AND SOCIETY. **The Climate Predictability Tool** Disponível em <https://iri.columbia.edu/our-expertise/climate/tools/cpt/>, 2019.

JANOWIAK, John E. A gridded data base of daily temperature maxima and minima for the conterminous United States, 1948-1993. US Department of Commerce, National Oceanic and Atmospheric Administration, **National Weather Service**, 1999.

JACINTO, L. V., ELOI, W. M., SAKAMOTO, M. S. Características Climatológicas dos Sistemas Convectivos de Mesoescala no Nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 37, p. 69-80, 2022.

JI, M.; KUMAR, A.; LEETMAA, A. A multiseason climate forecast system at the National Meteorological Center. **Bulletin of the American Meteorological Society**, v. 75, n. 4, p. 569-578, 1994.

JUNENG, L; TANGANG, F.T. Level and source of predictability of seasonal rainfall anomalies in Malaysia using canonical correlation analysis. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, v. 28, n. 9, p. 1255-1267, 2008.

KATZ, R.W.; PARLANGE, M.B.; TEBALDI, C. Stochastic modeling of the effects of large-scale circulation on daily weather in the southeastern US. In: **Issues in the Impacts of Climate Variability and Change on Agriculture**. Springer, Dordrecht, p. 189-216, 2003.

KAVETSKI, D.; KUCZERA, G.; FRANKS, S.W. Bayesian analysis of input uncertainty in hydrological modeling: 2. Application. **Water resources research**, v. 42, n. 3, 2006.

KAYANO, M. T.; ANDREOLI, R. V. Clima da Região Nordeste do Brasil. In: CAVALCANTI, I. F. A.; FERREIRA, N. J.; JUSTI DA SILVA, M. G. A.; SILVA DIAS, M. A. F.(org). **Tempo e clima no Brasil**, p.135-147, São Paulo: Oficina de Textos, 2009.

KAYANO, M.T.; ANDREOLI, R.V.; SOUZA, R.A.F.; GARCIA, S.R.; CALHEIROS A.J. El Niño e La Niña dos últimos 30 anos: diferentes tipos. **Revista Climanalise. Edição Comemorativa de**, v. 30, p. 7-12, 2016.

KELLEY, M.; SCHMIDT, G.A.; NAZARENKO, L.S.; BAUER, S.E.; RUEDY, R.; RUSSELL, G.L.; YAO, M.S. GISS-E2. 1: Configurations and climatology. **Journal of Advances in Modeling Earth Systems**, v. 12, n. 8, p. e2019MS002025, 2020.

KIPKOGEL, O.; MWANTHI, A.M.; MWESIGWA, J.B., ATHERU, Z.K.K.; WANZALA, M.A.; ARTAN. G. Improved seasonal prediction of rainfall over East Africa for application in agriculture: statistical downscaling of CFSv2 and GFDL-FLOR. **Journal of Applied Meteorology and Climatology**, v. 56, n 12, p. 3229-3243, 2017.

KIRTMAN, B.P.; MIN, D.; INFANTI, J.M.; KINTER, J.L.; PAOLINO, D.A.; ZHANG, Q.; WOOD ,E.F. The North American multimodel ensemble: phase-1 seasonal-to-interannual prediction; phase-2 toward developing intraseasonal prediction. **Bulletin of the American Meteorological Society**, v. 95, n. 4, p. 585-601, 2014.

KOUSKY, V.E. Frontal influences on northeast Brazil. **Monthly Weather Review**, v. 107, n. 9, p. 1140-1153, 1979.

KOUSKY, V.E. Diurnal rainfall variation in northeast Brazil. **Monthly Weather Review**, v. 108, n. 4, p. 488-498, 1980.

LANDMAN, W.A.; BARNSTON, A.G.; VOGEL, C.; SAVY, J. Use of El Niño–Southern Oscillation related seasonal precipitation predictability in developing regions for potential societal benefit. **International Journal of Climatology**, v. 39, n. 14, p. 5327-5337, 2019.

LANDMAN, W.A.; MASON, S.J. Operational long-lead prediction of South African rainfall using canonical correlation analysis. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, v. 19, n. 10, p. 1073-1090, 1999.

LATIF, M.; FLÜGEL, M. An investigation of short-range climate predictability in the tropical Pacific. **Journal of Geophysical Research: Oceans**, v. 96, n. C2, p. 2661-2673, 1991.

- LEUNG, L. R.; HAMLET, A. F.; LETTENMAIER, D. P.; KUMAR, A. "Simulations of the ENSO Hydroclimate Signals in the Pacific Northwest Columbia River Basin", *Bull. Am. Soc.*, 80(11), 2313-2329, 1999.
- LIM, Y., JO, S., LEE, J., OH, H-S., AND KANG, H-S. An improvement of seasonal climate prediction by regularized canonical correlation analysis. **International Journal of Climatology**, 2011. doi: 10.1002/joc.2368.
- LIMA, R.D.C.C; CAVALCANTE, A.D.M.B.; PEREZ-MARIN, A.M. Desertificação e mudanças climáticas no semiárido brasileiro. **Campina Grande: INSA-PB**, 2011.
- LIN, H., MERRYFIELD, W.J., MUNCASTER, R., SMITH, G.C., MARKOVIC, M., DUPONT, F., ROY, F., LEMIEUX, J-F., DIRKSON, A., KHARIN, V.V., LEE, W-S., CHARRON, M., AND ERFANI, A. The Canadian Seasonal to Interannual Prediction System Version 2 (CanSIPsv2). **Weather and Forecasting**, v. 35, n. 4, p. 1317-1343, 2020.
- LIU, B.; LIU, F.; WANG, C.; MEI, S. Unit commitment considering flexibility and uncertainty of wind power generation. **Power System Technology**, 39: 730–736, 2015.
- LORENZ, E.N. The predictability of a flow which possesses many scales of motion. **Tellus**, v. 21, n. 3, p. 289-307, 1969.
- LUCIO, P.S., et al Um modelo estocástico combinado de previsão sazonal para a precipitação no Brasil. **Revista Brasileira de Meteorologia**, v. 25, n. 1, p. 70-87, 2010.
- LYRA, M.J.A.; FEDOROVA, N.; LEVIT, V.; FREITAS, I.G.F.D. Características dos Complexos Convectivos de Mesoescala no Nordeste Brasileiro. **Revista Brasileira de Meteorologia**, v. 35, p. 727-734, 2020.
- LYRA, M. J. A. Vórtices ciclônicos de altos níveis do Nordeste brasileiro: sua relação com o transporte de umidade da América do Sul e sua estrutura termodinâmica. 2022.
- MA, F.; LIN, Y.S.; ZHANG, X.; LEE, C. Metamateriais terahertz multibanda sintonizáveis usando um arranjo ressonador elétrico de anel dividido reconfigurável. **Light: Science & Applications**, v. 3, n. 5, p. e171-e171, 2014.
- MA, H.-Y., XIE, S., KLEIN, S., WILLIAMS, K., BOYLE, J., BONY, S., DOUVILLE, H., FERMEPIN, S., MEDEIROS, B., TYTECA, S., WATANABE, M., AND WILLIAMSON, D. On the Correspondence between Mean Forecast Errors and Climate Errors in CMIP5 Models. **Journal of Climate**, v. 27, p. 1781–1798, 2014.
- MADDEN, R.A.; JULIAN, P.R. Detection of a 40–50 day oscillation in the zonal wind in the tropical Pacific. **Journal of Atmospheric Sciences**, v. 28, n. 5, p. 702-708, 1971.

MARENGO, J. A. Mudanças Climáticas Globais e seus Efeitos sobre a Biodiversidade. Caracterização do Clima Atual e Definição das Alterações Climáticas para o Território Brasileiro ao longo do Século XXI. **Ministério do Meio Ambiente. Secretaria de Biodiversidade e Florestas**. 212 p. MMA, 2006.

MARENGO, J.A. Tempo e clima no Brasil. [CAVALCANTI, I.F.A., FERREIRA, N.J., SILVA, M.G.A.J., DIAS, M.A.F.S. (org.)]. Cap. 25. Oficina de Textos, São Paulo, 2009.

MARENGO, J.A.; VALVERDE, M.C. Caracterização do clima no Século XX e Cenário de Mudanças de clima para o Brasil no Século XXI usando os modelos do IPCC-AR4. **Revista Multiciência**, v. 8, p. 5-28, 2007.

MARENGO, J.A.; BERNASCONI, M. Regional differences in aridity/drought conditions over Northeast Brazil: present state and future projections. **Climatic Change**, v. 129, n. 1, p. 103-115, 2015.

MARENGO, J.A.; ALVES, L.M.; ALVALA, R.C.S.; CUNHA, A.P.; BRITO, S. MORAES, O.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, 2017.

MARENGO, J.A.; TORRES, R.R.; ALVES, L.M. Drought in Northeast Brazil—past, present, and future. **Theoretical and Applied Climatology**, v. 129, n. 3, p. 1189-1200, 2017.

MASON, SIMON J.; TIPPETT, MICHAEL K. Climate Predictability Tool version 15.6. 1. 2017.

MCPHADEN, M.J.; BUSALACCHI, A.J.; ANDERSON, D.L.T. A toga retrospective. **Oceanography**, v. 23, n. 3, p. 86-103, 2010.

MERRYFIELD, W.J.; LEE, W.S.; BOER, G.J.; KHARIN, V.V.; SCINOCCA, J.F.; FLATO, G.M.; AJAYAMOHAN, R.S.; FYFE, J.C.; TANG, Y.; POLAVARAPU, S. The Canadian seasonal to interannual prediction system. Part I: Models and initialization. **Monthly weather review**, v. 141, n. 8, p. 2910-2945, 2013.

MICHOT, V.; VILA, D.; ARVOR, D.; CORPETTI, T.; RONCHAIL, J.; FUNATSU, B.M.; Dubreuil, V. Performance of TRMM TMPA 3B42 V7 in Replicating Daily Precipitation and Regional Precipitation Regimes in the Amazon Basin (1998–2013). **Remote Sens**. 2018, 10, 1879.

MO, Ruping; STRAUS, David M. Statistical–dynamical seasonal prediction based on principal component regression of GCM ensemble integrations. **Monthly Weather Review**, v. 130, n. 9, p. 2167-2187, 2002.

MOLION, L.C.B.; BERNARDO, S. Uma revisão da dinâmica das chuvas no Nordeste Brasileiro. **Revista Brasileira de Meteorologia**, v. 17, n. 1, p. 1-10, 2002.

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 the atmospheric sciences**, v. 38, n. 12, p. 2653-2675, 1981.

NAJAFI, M.R.; MORADKHANI, H. Hamid. Multi-model ensemble analysis of runoff extremes for climate change impact assessments. **Journal of Hydrology**, v. 525, p. 352-361, 2015.

NARAPUSETTY, B.; MURTUGUDDE, R.; WANG, H.; KUMAR, A. Ocean-atmosphere processes associated with enhanced Indian monsoon break spells in CFSv2 forecasts. **Climate Dynamics**, v. 51, n. 7, p. 2623-2636, 2018.

NEELIN, J.D. Interannual oscillations in an ocean general circulation model coupled to a simple atmosphere model. **Philosophical Transactions of the Royal Society of London. Series A, Mathematical and Physical Sciences**, v. 329, n. 1604, p. 189-205, 1989.

NEELIN, J.D. A hybrid coupled general circulation model for El Niño studies. **Journal of Atmospheric Sciences**, v. 47, n. 5, p. 674-693, 1990.

NAMIAS, J. Influence of northern hemisphere general circulation on drought in northeast Brazil 1. **Tellus**, v. 24, n. 4, p. 336-343, 1972.

NOBRE, C. A.; CAVALCANTI, I. F. A.; GAN, M. A.; NOBRE, P.; KAYANO, M. T.; RAO, V.B.; BONATTI, J. P.; SATYAMURTY, P.; UVO, C. B.; COHEN, J. C. Climanálise – Boletim de Monitoramento e Análise Climática. Número Especial. Aspectos da Climatologia Dinâmica do Brasil. **Instituto Nacional de Meteorologia-INMET**. Brasília- DF, outubro 1986.

NOGUÉS-PAEGLE, J.; MECHOSO, C.R.; FU, R.; BERBERY, E.H.; CHAO, W.C.; CHEN, T.C.; ... ZHOU, J. Progress in Pan American CLIVAR research: understanding the South American monsoon. **Meteorologica**, v. 27, n. 12, p. 1-30, 2002.

OSMAN, M., COELHO, C. A., & VERA, C. S. Calibration and combination of seasonal precipitation forecasts over South America using Ensemble Regression. **Climate Dynamics**, v. 57, n. 9, p. 2889-2904, 2021.

OU, M.H., CHARLES, M., AND COLLINS, D.C. Sensitivity of calibrated week-2 probabilistic forecast skill to reforecast sampling of the NCEP global ensemble forecast system. **Weather and Forecasting**, v. 31, n. 4, p. 1093-1107, 2016.

OYAMA, M.D.; NOBRE, C.A. A new climate-vegetation equilibrium state for Tropical South America. **Geophysical Research Letter**, v. 30, n. 23, p. 2199, 2003.

PAI, D.S.; RAO, A.S.; SENROY, S.; PRADHAN, M.; PILLAI, P.A.; RAJEEVAN, M. Performance of the operational and experimental long-range forecasts for the 2015 southwest monsoon rainfall. **Current Science**, p. 68-75, 2017.

- PALMER, T.N.; ANDERSON, D.L.T. The prospects for seasonal forecasting—A review paper. **Quarterly Journal of the Royal Meteorological Society**, v. 120, n. 518, p. 755-793, 1994.
- PAREDES-TREJO, F.; BARBOSA, H.; DOS SANTOS, C.A.C. Evaluation of the performance of SM2RAIN-derived rainfall products over Brazil. **Remote Sensing**, v. 11, n. 9, p. 1113, 2019.
- PBMC. Sumário Executivo do Volume 1 - Base Científica das Mudanças Climáticas. Contribuição do Grupo de Trabalho 1 para o 1º Relatório de Avaliação Nacional do Painel Brasileiro de Mudanças Climáticas. **Volume Especial para a Rio+20**. Rio de Janeiro, Brasil, p. 34, 2012.
- PENG, Y.; ZHAO, X.; WU, D.; TANG, B.; XU, P.; DU, X.; WANG, H. Spatiotemporal variability in extreme precipitation in China from observations and projections. **Water**, v. 10, n. 8, p. 1089, 2018.
- PINTO, J.G.; REYERS, M.; ULBRICH, U. The variable link between PNA and NAO in observations and in multi-century CGCM simulations. **Climate dynamics**, v. 36, n. 1, p. 337-354, 2011.
- RAJEEVAN, M.; PAI, D.S.; ANIL KUMAR, R.; LAL, B. New statistical models for long-range forecasting of southwest monsoon rainfall over India. **Climate Dynamics**, v. 28, n. 7, p. 813-828, 2007.
- RAO, V.B.; HADA, K. Characteristics of rainfall over Brazil: Annual variations and connections with the Southern Oscillation. **Theoretical and applied climatology**, v. 42, n. 2, p. 81-91, 1990.
- RAO, V. B.; LIMA, M.; FRANCHITO, S. H. Seasonal and Interannual Variations of Rainfall over Eastern Northeast Brazil. **Journal of Climate**, v. 6, p. 1754-1763, 1993.
- RASMUSSEN, E.M.; CARPENTER, T.H. The relationship between eastern equatorial Pacific sea surface temperatures and rainfall over India and Sri Lanka. **Monthly Weather Review**, v. 111, n. 3, p. 517-528, 1983.
- REBOITA, M.S.; PINTO, S.S.; KRUSCHE, N. Variação climatológica não-sazonal através da análise de componentes principais, 2002.
- REBOITA, M. S.; GAN, M. A.; ROCHA, R. P.; AMBRIZZI, T. Regimes de precipitação na América do Sul: uma revisão bibliográfica. **Revista Brasileira de Meteorologia**, 25, 185-204, 2010.
- REPELLI, C.A.; NOBRE, P. Statistical prediction of sea-surface temperature over the tropical Atlantic. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, v. 24, n. 1, p. 45-55, 2004.

REPINALDO, H.F.B.; FEDOROVA, N.; LEVIT, V.; REPINALDO, C.R.D.R. Vórtice Ciclônico em Altos Níveis e Corrente de Jato do Nordeste Brasileiro sobre o Estado de Alagoas: Padrões de Circulação e Precipitação. **Revista Brasileira de Meteorologia**, v. 35, n. spe, p. 745-754, 2020.

RIBEIRO, A.; VICTORIA, R.L.; PEREIRA, A.R.; VILLA NOVA, N.A.; MARTINELLI, L.A.; MORTATTI, J. Análise do Regime pluviométrico da região Amazônica a partir de dados de onze localidades. **Revista Brasileira de Meteorologia**, v. 11, n. 1, p. 25-26, 1996.

RODRIGUES, D.T.; SILVA, C.M.S.; REIS, J.S.; PALHARINI, R.S.A.; CABRAL JÚNIOR, J.B.; SILVA, H.J.F.; MUTTI, P.R.; BEZERRA, B.G.; GONÇALVES, W.A. Evaluation of the Integrated Multi-SatellitE Retrievals for the Global Precipitation Measurement (IMERG) Product in the São Francisco Basin (Brazil). *Water*, 13, 2714, 2021.

RODRIGUES, L.R.L.; DOBLAS-REYES, F.J.; COELHO, C.A.S. Calibration and combination of monthly near-surface temperature and precipitation predictions over Europe. **Climate Dynamics**, v. 53, n. 12, p. 7305-7320, 2019.

ROPELEWSKI, C.F.; HALPERT, M.S. Global and regional scale precipitation patterns associated with the El Niño/Southern Oscillation. **Monthly weather review**, v. 115, n. 8, p. 1606-1626, 1987.

ROSER, M.; ORTIZ-OSPINA, E. LITERACY. **Our World in Data**, 2016.

ROY, T.; HE, X.; LIN, P.; BECK, H.E.; CASTRO, C.; WOOD, E.F. Global evaluation of seasonal precipitation and temperature forecasts from NMME. **Journal of Hydrometeorology**, v. 21, n. 11, p. 2473-2486, 2020.

SACHINDRA, D.A.; HUANG, F.; BARTON, A.; PERERA, B.J.C. Redução estatística das saídas do modelo de circulação geral para precipitação – parte 1: calibração e validação. **Revista Internacional de Climatologia**, v. 34, n. 11, p. 3264-3281, 2013.

SAHA, S.; MOORTHY, S.; WU, X.; WANG, J.; NADIGA, S.; TRIPP, P.; BEHRINGER, D.; HOU, Y.; CHUANG, H.Y.; IREDELL, M.E.; K.M.; MENG, J.; YANG, R.; MENDEZ, M.P.; DOOL, H.V.D.; ZHANG, Q.; WANG, W.; CHEN, M.; BECKER, E. The NCEP climate forecast system version 2. **Journal of climate**, v. 27, n. 6, p. 2185-2208, 2014.

SARDESHMUKH, P.D.; HOSKINS, B.J. The generation of global rotational flow by steady idealized tropical divergence. **Journal of the Atmospheric Sciences**, v. 45, n. 7, p. 1228-1251, 1988.

SARMENTO, F. J. Previsibilidade De Eventos Hidrológicos No Semiárido Brasileiro– Parte I. **XXIV Simposio brasileiro de Recursos Hídricos**, 21 a 26 de novembro, belo Horizonte, Minas Gerais 2021.

SCHEPEN, A.; WANG, Q.J. Ensemble forecasts of monthly catchment rainfall out to long lead times by post-processing coupled general circulation model output. **Journal of Hydrology**, v. 519, p. 2920-2931, 2014.

SCHEPEN, A.; WANG, Q.J.; ROBERTSON, D.E. Seasonal forecasts of Australian rainfall through calibration and bridging of coupled GCM outputs. **Monthly Weather Review**, v. 142, n. 5, p. 1758-1770, 2014.

SHUKLA, S.; LETTENMAIER, D.P. Multi-RCM ensemble downscaling of NCEP CFS winter season forecasts: Implications for seasonal hydrologic forecast skill. **Journal of Geophysical Research: Atmospheres**, v. 118, n. 19, p. 10,770-10,790, 2013.

SILVA, EMERSON. R. M. DA; BARBOSA, IVAN C. DA C.; SILVA, HELDER J. F. DA; COSTA, LUIZ GONZAGA DA S; ROCHA, EDSON J. P. DA. Análise do Desempenho da Estimativa de Precipitação do Produto CHIRPS para Sub-Bacia do Rio Apeú. **Revista Brasileira de Geografia Física**, Castanhal-PA, v. 13, n. 3, 2020.

SILVA, E.H.D.L.; SILVA, F.D.D.S.; JUNIOR, R.S.D.S.; PINTO, D.D.C.; COSTA, R. L.; GOMES, H.B.; JUNIOR J.B.C.; DE FREITAS I.G.F.; AND HERDIES, D.L. Performance Assessment of Different Precipitation Databases (Gridded Analyses and Reanalyses) for the New Brazilian Agricultural Frontier: **vter**, v. 14, n. 9, p. 1473, 2022.

SILVA, M. P. D. C. D., Pinto, J. E. S. D. S., & Castelhana, F. J. Análise da variabilidade pluvial e sua contribuição para o estudo do clima urbano do município de Feira de Santana-BA. **Geopauta**, v. 6, 2023.

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

SILVA, F.F.; DOS SANTOS, F.D.A.; DOS SANTOS, J.M. Índice de anomalia de chuva (iac) aplicado ao estudo das precipitações no município de caridade, ceará, brasil. **Revista Brasileira de Climatologia**, v. 27, 2020.

SLATER, L.J.; VILLARINI, G.; BRADLEY, A.A. Evaluation of the skill of North-American Multi-Model Ensemble (NMME) Global Climate Models in predicting average and extreme precipitation and temperature over the continental USA. **Climate Dynamics**, v. 53, n. 12, p. 7381-7396, 2019.

SMITH, R. E.; LIVEZEY, R. E., Covariability of aspects of North American Climate with Global Sea Surface Temperatures on Interannual to Interdecadal Timescales. **Journal of Climate**, 12, 289-302, 1999.

SOUZA, A.C.D.; CANDIDO, L.A.; ANDREOLI, R.V. Variabilidade interanual da precipitação e fluxo de umidade sobre a Amazônia usando o QTCM. **Revista Brasileira de Meteorologia**, v. 33, p. 41-56, 2018.

SOUZA, S. S.; TOMASELLA, J.; GRACIA, M. G.; AMORIM, M. C.; MENEZES, P. C. P.; PINTO, C. A. M. O Programa de monitoramento climático em tempo real na área de atuação da SUDENE – PROCLIMA **Boletim da Revista Brasileira de Meteorologia**, v. 25 n. 1, p. 15-24, 2001.

STEED, R.C., C.F. MASS, 2004: Bias removal on a mesoscale forecast grid. [Available online from <http://www.mmm.ucar.edu/mm5/workshop/ws04/Session2/ Steed.Rick.pdf>]

STOCKDALE, T.N.; ANDERSON, D.L.; ALVES, J.O.S.; BALMASEDA, M.A. Global seasonal rainfall forecasts using a coupled ocean–atmosphere model. **Nature**, v. 392, n. 6674, p. 370-373, 1998.

STUDZINSKI C.D. Um estudo da precipitação na região Sul do Brasil e sua relação com os oceanos Pacífico e Atlântico Tropical Sul. São José dos Campos, **Dissertação (Mestrado em Meteorologia) – INPE**, p.79, 1995.

THOMPSON, D.W.J; WALLACE, J.M. The Arctic Oscillation signature in the wintertime geopotential height and temperature fields. **Geophysical research letters**, v. 25, n. 9, p. 1297-1300, 1998.

TIPPETT, M.K.; RANGANATHAN, M.; L’HEUREUX, M.; BARNSTON, A.G.; DELSOLE, T. Assessing probabilistic predictions of ENSO phase and intensity from the North American Multimodel Ensemble. **Climate Dynamics**, v. 53, n. 12, p. 7497-7518, 2019.

TRENBERTH, K.E.; BRANSTATOR, G.W.; KAROLY, D.; KUMAR, A.; LAU, N.C.; ROPELEWSKI, C. Progress during TOGA in understanding and modeling global teleconnections associated with tropical sea surface temperatures. **Journal of Geophysical Research: Oceans**, v. 103, n. C7, p. 14291-14324, 1998.

TROCCOLI, A.; HARRISON, M.; COUGHLAN, M.; WILLIAMS, J.B. Seasonal forecasts in decision making. In: **Seasonal climate: forecasting and managing risk**. Springer, Dordrecht, p. 13-41, 2008.

UNGER, D.A.; VAN DEN DOOL, H.; O’LENIC, E.; COLLINS, D. Ensemble regression. **Monthly Weather Review**, v. 137, n. 7, p. 2365-2379, 2009.

UVO, C.R.B. A Zona de Convergência Intertropical (ZCIT) e sua relação com a precipitação da Região Norte do Nordeste Brasileiro. Dissertação (Mestrado em Meteorologia) - **Instituto Nacional de Pesquisas Espaciais**, São José dos Campos, Brasil, 81f, 1989.

VEBER, M.E.; FEDOROVA, N.; LEVIT, V. Desenvolvimento de Atividades Convectivas Sobre a Região Nordeste do Brasil, Organizada Pela Extremidade Frontal. **Revista Brasileira de Meteorologia**, v. 35, p. 995–1003, 2020.

VECCHI, G. A., DELWORTH, T., GUDGEL, R., KAPNICK, S., ROSATI, A., WITTENBERG, A. T., ... & ZHANG, S. On the seasonal forecasting of regional tropical cyclone activity. **Journal Clim.** 27, 7994_8016, 2014.

VIEGAS, J.; ANDREOLI, R.V.; KAYANO, M.T.; CANDIDO, L.A.; SOUZA, R.A.F.D.; HALL, D.H.; ... VALENTIN, W.I.D. Caracterização dos diferentes tipos de El Niño e seus impactos na América do sul a partir de dados observados e modelados. **Revista Brasileira de Meteorologia**, v. 34, p. 43-67, 2019.

WALKER, G.T. Correlation in seasonal variation of climate (Introduction). **Memoirs of India Meteorological Department**, v. 20, p. 117–124, 1908.

WALKER, G.T. Correlation in seasonal variations of weather, II, **Memoirs of India Meteorological Department**, v. 21, p. 22-30, 1910.

WALKER, G.T. A further study of relationships with Indian monsoon rainfall, II, **Memoirs of India Meteorological Department**, v. 23, p. 123-129, 1914.
23:123–129.

WALKER, G.T. Correlation in seasonal variations of weather, VIII, A preliminary study of world weather, **Memoirs of India Meteorological Department**, v. 24, p. 75–131, 1923.

WALLACE, J.M.; GUTZLER, D.S. Teleconnections in the geopotential height field during the Northern Hemisphere winter. **Monthly weather review**, v. 109, n. 4, p. 784-812, 1981.

WANG, Y.; LEUNG, L. R.; MCGREGOR, J. L.; LEE, D. K.; WANG, W. C.; DING, Y.; KIMURA, F. “Regional Climate Modeling: Progress, Challenges, and Prospects”, **Journal of Meteorological Society of Japan**, 82 (6), 1599-1628, 2004.

WANG, Q.J.; ROBERTSON, D.E. Multisite probabilistic forecasting of seasonal flows for streams with zero value occurrences. **Water Resources Research**, v. 47, n. 2, 2011.

WANG, Q.J.; ROBERTSON, D.E.; CHIEW, F.H.S. Uma abordagem de modelagem de probabilidade conjunta Bayesiana para previsão sazonal de vazões em vários locais. **Pesquisa de Recursos Hídricos**. v. 45, n. 5, 2009.

WILKS, D.S. **Statistical methods in the atmospheric sciences**. Academic press, 2011.

WILKS, D.S.; HAMILL, T.M. Comparison of ensemble-MOS methods using GFS reforecasts. **Monthly weather review**, v. 135, n. 6, p. 2379-2390, 2007.

WILLIAMS, P.D.; ALEXANDER, M.J.; BARNES, E.A.; BUTLER, A.H.; DAVIES, H.C.; GARFINKEL, C.I.; ... ZHANG, C. A census of atmospheric variability from seconds to decades. **Geophysical Research Letters**, v. 44, n. 21, p. 11,201-11,211, 2017.

WOOD, A. W.; MAURER, E. P.; KUMAR, A.; LETTENMAIER, D. P. Longrange

experimental hydrologic forecasting for the eastern United States. **Journal of Geophysical Research**. V.107, n.20, p.6(1-15). 2002.

WU, D.H.; ANDERSON, D.L.T.; DAVEY, M.K. ENSO prediction experiments using a simple ocean-atmosphere model. **Tellus A**, v. 46, n. 4, p. 465-480, 1994.

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

Xavier, A. C., Scanlon, B. R., King, C. W., & Alves, A. I. New improved Brazilian daily weather gridded data (1961–2020). *International Journal of Climatology*, v. 42, n. 16, p. 8390-8404, 2022.

ZANELLA, M.E. Considerações sobre o clima e os recursos hídricos do semiárido nordestino. **Caderno Prudentino de Geografia**, v. 1, n. 36, p. 126-142, 2014.

ZEBIAK, S.E.; CANE, M.A. A model el niñ–southern oscillation. **Monthly Weather Review**, v. 115, n. 10, p. 2262-2278, 1987.

ZHANG, YUEFEN; WU, CHUANHAO; YEH, PAT J.-F.; LI, JIANZHU; HU, BILL X.; FENG, PING; JUN, CHANGHYUN. Evaluation and comparison of precipitation estimates and hydrologic utility of CHIRPS, TRMM 3B42 V7 and PERSIANN-CDR products in various climate regimes. **Atmospheric Research**, v. 265, p. 105881, 2022.

ZHANG, C. Madden-Julian Oscillation. **Reviews of Geophysics**, v. 43, p. 1–36, 2005.

ZHANG, H.; CISSE, M.; DAUPHIN, Y.N.; LÓPEZ -PAZ, D. mixup: Beyond empirical risk minimization. **arXiv preprint arXiv:1710.09412**, 2017.

ZHAO, T., BENNETT, J., WANG, Q.J., SCHEPEN, A., WOOD, A., ROBERTSON, D., AND RAMOS, M-H. How suitable is quantile mapping for post-processing GCM precipitation forecasts? **Journal of Climate**, v. 30, p. 3185-3196, 2017.

ZHOU, J.; LAU, K.M. Principal modes of interannual and decadal variability of summer rainfall over South America. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, v. 21, n. 13, p. 1623-1644, 2001.

ZHOU, S.; L'HEUREUX, M.; WEAVER, S.; KUMAR, A. A composite study of the MJO influence on the surface air temperature and precipitation over the continental United States. **Climate dynamics**, v. 38, n. 7, p. 1459-1471, 2012.