

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

GEIZA THAMIRYS CORREIA GOMES

**DOWNSCALING ESTATÍSTICO APLICADO A PREVISÃO CLIMÁTICA DE
PRECIPITAÇÃO PARA A BACIA HIDROGRÁFICA DO RIO MUNDAÚ**

MACEIÓ – AL

2023

GEIZA THAMIRYS CORREIA GOMES

**DOWNSCALING ESTATÍSTICO APLICADO A PREVISÃO CLIMÁTICA DE
PRECIPITAÇÃO PARA A BACIA HIDROGRÁFICA DO RIO MUNDAÚ**

Dissertação de mestrado apresentada ao Programa de Pós-graduação em Meteorologia da Universidade Federal de Alagoas, como parte do requisito para o grau de mestre em meteorologia.

Orientador: Professor Dr. Fabrício Daniel dos Santos Silva.

Co-Orientador: Professora Dra. Maria Luciene Dias de Melo.

MACEIÓ – AL

2023

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

Bibliotecária: Taciana Sousa dos Santos – CRB-4 – 2062

G633d Gomes, Geiza Thamirys Correia.

Downscaling estatístico aplicado à previsão climática de precipitação para a bacia hidrográfica do rio Mundaú / Geiza Thamirys Correia Gomes. – 2023.

74 f. : il. color.

Orientador: Fabrício Daniel dos Santos Silva.

Coorientador: Maria Luciene Dias de Melo.

Dissertação (Mestrado em Meteorologia) – Universidade Federal de Alagoas. Instituto de Ciências Atmosféricas. Programa de Pós-Graduação em Meteorologia. Maceió, 2023.

Bibliografia: f. 67-74.

1. Previsões climáticas. 2. Bacia hidrográfica. 3. Mundaú, Rio (AL). I. Título.

CDU: 551.509 (813.5)



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

CERTIFICADO DE APRESENTAÇÃO

N.º de ordem: MET-UFAL-MS-198.

*"DOWNSCALING ESTATÍSTICO APLICADO A PREVISÃO CLIMÁTICA DE PRECIPITAÇÃO
PARA A BACIA HIDROGRÁFICA DO RIO MUNDAÚ."*

GEIZA THAMIRYS CORREIA GOMES

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

Aprovado pela Banca Examinadora composta por:

 Documento assinado digitalmente
FABRÍCIO DANIEL DOS SANTOS SILVA
Data: 01/02/2023 11:00:01-0300
Verifique em: <https://verificador.brpf>

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

 Documento assinado digitalmente
MARIA LUCIENE DIAS DE MELO
Data: 01/02/2023 12:00:45-0300
Verifique em: <https://verificador.brpf>

Profa. Dra. Maria Luciene Dias de Melo
(Coorientadora)

 Documento assinado digitalmente
GLAUBER LOPES MARIANO
Data: 01/02/2023 11:07:08-0300
Verifique em: <https://verificador.brpf>

Prof. Dr. Glauber Lopes Mariano
(Membro Interno)

 Documento assinado digitalmente
JONATHAN MOTA DA SILVA
Data: 02/02/2023 08:11:30-0300
Verifique em: <https://verificador.brpf>

Prof. Dr. Jonathan Mota da Silva
(Membro Externo)

FEVEREIRO/2023

RESUMO

Produzir previsões climáticas sub sazonais é crucial para muitos setores econômicos e tem grande relevância para a sociedade como um todo. Diferentes eventos climáticos atuam na região Nordeste do Brasil condicionando sucesso ou fracasso em atividades agrícolas, impactos nos recursos hídricos e períodos de extremos secos ou úmidos. A Bacia Hidrográfica do Rio Mundaú (BHM), é uma das mais importantes para os estados de Alagoas e Pernambuco, de clima tropical/semiárido onde o curso d'água e extensão territorial da bacia cruza e divide os dois estados. Nessa bacia há ocorrências cíclicas de grandes períodos de estiagens e enxurradas severas. Diante desta problemática, o objetivo deste estudo foi regionalizar as previsões climáticas do modelo francês Méteo-France System 7 (MFS7) para a BHM utilizando a técnica de Análise de Correlações Canônicas (ACC), que permite recalibrar as previsões climáticas retrógradas de um modelo confrontando-as com as observações em uma área, e avaliar a sua destreza após isso. A previsão de cada mês foi obtida com até cinco meses de antecedência no período 1993-2016 e analisada de forma determinística por meio da correlação entre valores simulados e observados, mostrando como principal resultado que a previsão para determinado mês realizada exatamente com um mês de precedência, geralmente, fornece a previsão mais precisa, embora essa não seja uma regra para todos os meses do ano. No entanto, percebeu-se que ao aplicar uma previsão média por conjuntos, a partir da média de todas as cinco previsões anteriores, as correlações são significativamente aumentadas entre essa previsão média e as observações, além da diminuição dos erros relativos à previsão. A rede de observações na BHM não é ampla e a fonte dos observada utilizada foi do *Climate Hazards Group InfraRed Precipitation with Station data* (CHIRPS), que se mostrou eficiente para estimativa das chuvas acumuladas mensais na BHM quando comparada as poucas séries observadas. Após avaliação das previsões recalibradas com ACC, um estudo de caso foi realizado aplicando a previsão por conjuntos para todos os meses do ano de 2020, com resultados que indicaram previsões climáticas condizentes com as observações desse mesmo ano, demonstrando o potencial operacional de utilização dos dados climáticos do MFS7 para gerar previsões climáticas confiáveis para a BHM.

Palavras-chave: Previsões climáticas, Precipitação acumulada mensal, CHIRPS, BHM, MFS7.

ABSTRACT

Producing sub-seasonal climate forecasts is crucial for many economic sectors and has great relevance for society as a whole. Different climatic events act in the Northeast region of Brazil, conditioning success or failure in agricultural activities, recharge or shortage of water resources, periods of dry or humid extremes. The Mundaú River Basin (BHM) is one of the most important for the states of Alagoas and Pernambuco, with a tropical/semi-arid climate where the watercourse and territorial extension of the basin crosses and divides the two states. In this basin there are cyclic occurrences of long periods of drought and severe floods. Faced with this problem, the objective of the present study was to regionalize the climate forecasts of the French model Météo-France System 7 (MFS7) for the BHM using the Canonical Correlation Analysis (ACC) technique, which allows recalibrating the retrograde climate forecasts of a model confronting them with observations in one area, and evaluating their dexterity after that. The forecast for each month was obtained up to five months in advance in the period 1993-2016 and analyzed deterministically through the correlation between simulated and observed values, showing as the main result that the forecast for a given month was carried out exactly one month in advance, generally provides the most accurate forecast, although this is not a rule for every month of the year. However, it was noticed that when applying an average prediction by sets, from the average of all five previous predictions, the correlations are significantly increased between this average prediction and the observations, in addition to the decrease of errors related to the prediction. The network of observations in the BHM is not extensive and the source of the observations used was from the Climate Hazards Group InfraRed Precipitation with Station data (CHIRPS), which proved to be efficient for estimating the monthly accumulated rainfall in the BHM when compared to the few observed series. After evaluating the recalibrated forecasts with ACC, a case study was carried out applying the set forecast for all months of the year 2020, with encouraging results that indicated climate forecasts consistent with the observations of that same year, demonstrating the operational potential of using the weather data from the MFS7 to generate reliable weather forecasts for the BHM.

Keywords: Climate forecasts, Monthly cumulative precipitation, CHIRPS, BHM, MFS7.

LISTA DE FIGURAS

Figura 1 – Domínio do preditor X e do preditando Y (acima) e (abaixo) processo de redução do número de variáveis (pontos de grade) para obter séries independentes (ortogonais entre si).	8
Figura 2 – Localização da Bacia Hidrográfica do rio Mundaú (BHM).	13
Figura 3 – Distribuição espacial dos pontos extraídos do CHIRPS na BHM, com resolução espacial de 0,05°.	14
Figura 4 – Componentes do modelo CNRM-CM do sistema de previsão sazonal.	15
Figura 5 – Domínio usado no CPT.	19
Figura 6 – Exemplo de construção do diagrama de Taylor.	23
Figura 7 – Diagrama de dispersão entre valores mensais observados em estações da ANA na BHM, e estimados pelo CHIRPS para as coordenadas geográficas dessas estações em dias com ocorrência de precipitação.	24
Figura 8 – Climatologia anual, 1981 a 2020.	25
Figura 9 – Climatologia sazonal.	26
Figura 10 – Climatologia mensal.	27
Figura 11 – Correlações entre observações e previsões geradas para o mês de janeiro variando de um a cinco meses de antecedência (dezembro a agosto do ano anterior). ...	30
Figura 12 – Idêntica a figura 18, mas para fevereiro.	31
Figura 13 – Idêntica a figura 18, mas para março.	32
Figura 14 – Idêntica a figura 18, mas para abril.	32
Figura 15 – Idêntica a figura 18, mas para maio.	33
Figura 16 – Idêntica a figura 18, mas para junho.	34
Figura 17 – Idêntica a figura 18, mas para julho.	35
Figura 18 – Idêntica a figura 18, mas para agosto.	36
Figura 19 – Idêntica a figura 18, mas para setembro.	36
Figura 20 – Idêntica a figura 18, mas para outubro.	37
Figura 21 – Idêntica a figura 18, mas para novembro.	37
Figura 22 – Idêntica a figura 18, mas para dezembro.	38
Figura 23 – MAE da média das previsões de cada mês do ano.	39
Figura 24 – RMSE da média das previsões de cada mês do ano.	40
Figura 25 – Aplicação do diagrama de Taylor representando graficamente as estatísticas relativas as observações e previsões obtidas até cinco meses antes do mês atual, para janeiro, fevereiro, março, abril, maio e junho.	42
Figura 26 – Aplicação do diagrama de Taylor representando graficamente as estatísticas relativas as observações e previsões obtidas até cinco meses antes do mês atual, para julho, agosto, setembro, outubro, novembro e dezembro.	43
Figura 27 – Correlações entre observações e previsões por conjunto para cada mês do ano.	45
Figura 28 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para janeiro de 2020 (painel inferior).	48
Figura 29 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para fevereiro de 2020 (painel inferior).	48
Figura 30 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para março de 2020 (painel inferior).	49

Figura 31 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para abril de 2020 (painel inferior).....	49
Figura 32 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para maio de 2020 (painel inferior).	50
Figura 33 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para junho de 2020 (painel inferior).....	50
Figura 34 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para julho de 2020 (painel inferior).....	51
Figura 35 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para agosto de 2020 (painel inferior).....	51
Figura 36 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para setembro de 2020 (painel inferior).....	52
Figura 37 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para outubro de 2020 (painel inferior).....	52
Figura 38 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para novembro de 2020 (painel inferior).	53
Figura 39 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para dezembro de 2020 (painel inferior).....	53

LISTA DE ABREVIATURAS E SIGLAS

ACC	Análise de Correlações Canônicas
ACP	Análise de Componentes Principais
AGCMs	Modelo Dinâmico de Circulação Geral Global Atmosféricos
ANA	Agência Nacional de Águas e Saneamento Básico
BAM	Modelo Atmosférico Global Brasileiro
BHM	Bacia Hidrográfica do rio Mundaú
CELMM	Complexo Estuarino Lagunar Mundaú-Manguaba
CGCMs	Modelo Dinâmico de Circulação Geral Global Acoplados
CHIRPS	Climate Hazards Group InfraRed Precipitation with Station data
CHPClim	Climate Hazards Center's Precipitation Climatology
CNRM	Centre National de Recherches Météorologiques
Cov	Covariância
CP	Componentes Principais
CPC	Climate Prediction Center
CPTEC	Centro de Previsão de Tempo e Estudos Climáticos
CPT	Climate Predictability Tool
DOL	Distúrbio Ondulatório de Leste
ECMWF	European Centre for Medium-Range Weather Forecasts
ENOS	El Niño-Oscilação do Sul
EOF	Empirical Orthogonal Function
EUROBRISA	EURO-Brazilian Initiative for Improving South American Seasonal Forecasts
GCMs	Modelos de Circulação Global
GTS	Sistema Global de Telecomunicações
INMET	Instituto Nacional de Meteorologia
INPE	Instituto Nacional de Pesquisas Espaciais
IRI	International Research Institute for Climate Society
KMA	Korea Meteorological Agency
MAE	Erro Médio Absoluto
MFS7	Meteo-France-System 7
NCDC	National Climatic Data Center
NCEP	National Center for Environmental Prediction

NEMO	Nucleus for European Modeling of the Ocean
NMME	North American Multi-Model Ensemble
NOAA	National Oceanic and Atmospheric Administration
OMM	Organização Mundial de Meteorologia
r	Coefficiente de correlação de Pearson
RLM	Regressão Linear Múltipla
RMSE	Root Mean Squared Error (Erro quadrático médio)
SEALBA	Sergipe, Alagoas e Bahia
SURFEX	Surface Externalisée
TSM	Temperatura da Superfície do Mar
VCAN	Vórtice Ciclônico de Altos Níveis
ZCIT	Zona de Convergência Intertropical

Sumário

1. TRODUÇÃO.....	1
1.1 OBJETIVO GERAL	2
1.2 OBJETIVOS ESPECÍFICOS	2
2. REVISÃO BIBLIOGRÁFICA.....	2
2.1 Previsão Climática.....	2
2.2 Modelos Dinâmicos	4
2.3 Modelos Empíricos.....	5
2.4 <i>Downscaling</i> estatístico	9
2.5 CHIRPS.....	9
2.6 Clima e Variabilidade da Precipitação no Nordeste do Brasil.....	10
3. MATERIAL E MÉTODOS.....	12
3.1 Caracterização da Área de Estudo	12
3.2 Dados de Chuva Estimados pelo CHIRPS.....	13
3.3 Climatologia na BHM.....	14
3.4 Meteo-France - System 7	15
3.4.1 <i>Modelo atmosférico ASPERGE V6.4</i>	16
3.4.2 <i>Modelo oceânico NEMO V3.6 e modelo de gelo marinho GELATO V6</i>	16
3.4.3 <i>Modelo de superfície terrestre Surfex V8 e modelo de escoamento fluvial CTRIP</i>	17
3.4.4 <i>Precipitação do MFS7</i>	17
3.5 Software Climate Predictability Tool (CPT)	18
4. RESULTADOS	23
4.1 Dados de chuva estimados pelo CHIRPS	23
4.2 Climatologia da BHM	24
4.3 Previsão climática do MFS7 via ACC – análise das correlações mensais	29
4.4 Previsão climática do MFS7 via ACC – análise dos erros	38
4.5 Análise de diagramas de Taylor.....	41
4.6 Previsão climática por conjunto do MFS7 via ACC – análise das correlações.....	43
4.7 Previsões por conjunto para o ano de 2020 – estudo de caso.	46
5 CONCLUSÕES.....	54
6 REFERENCIAS BIBLIOGRAFICAS	55

1. INTRODUÇÃO

Prever o clima não é uma tarefa trivial. Envolve diferentes conceitos e objetivos. Conceitualmente, por décadas, houve divergência quanto à melhor forma de prever o clima com menos erros possíveis. Objetivamente, a grande questão era o alcance temporal e espacial confiável de uma previsão climática. De certa forma, essas duas questões evoluíram nas últimas décadas com o desenvolvimento de previsões climáticas produzidas por diversos centros em diferentes Países. Mas há de se ter cuidado ao nos referirmos as previsões climáticas, principalmente no que tange ao tempo, sendo estas sazonais ou subsazonais, que são previsões com determinadas condições médias de algumas variáveis, principalmente precipitação e temperatura, tenderão a se comportar nos próximos trimestres - sazonais (BARNSTON et al., 2010; SAHA et al., 2014; BOROVIKOV et al., 2019; JOHNSON et al., 2019; DA ROCHA JÚNIOR et al., 2021) ou no próximos meses a semanas - subsazonais (VITART et al., 2017; MARIOTTI; RUTI; RIXEN, 2018; MARIOTTI et al., 2020; MERRYFIELD et al., 2020).

Atualmente, previsões sazonais são produzidas regularmente pelos principais centros de previsão operacional do mundo e.g. Climate Change Service, com sistemas de previsões geralmente baseadas em conjuntos dinâmicos. Previsões por conjuntos são baseadas na média de diferentes membros sob distintas condições iniciais para um mesmo modelo, ou da média de mais de um modelo numérico onde são calculados conjuntos de previsões determinísticas, com cada membro do conjunto representando um resultado plausível do futuro. Tais previsões determinísticas são comparadas a um período de referência histórico (climatologia observada), que permitem desenvolver estatisticamente uma típica previsão probabilística, que ainda é a forma mais usual de divulgação da previsão climática, como feito pelo Centro de Previsão de Tempo e Estudos Climáticos (CPTEC) do Instituto Nacional de Pesquisas Espaciais (INPE). No entanto, há vieses tanto nas condições iniciais quanto nos próprios modelos de previsão dinâmica, sendo necessário avaliar as previsões geradas para um período no passado, conhecido pelo termo em inglês hindcast, que possam ser comparáveis as observações permitindo conhecer em detalhes as incertezas do modelo (KHARIN et al., 2012; BATTÉ et al., 2019). Assim, quanto mais extenso o conjunto de hindcast, maior a qualidade das inferências acerca da confiabilidade das previsões dos modelos.

Previsões de precipitação sazonal tem destaque para diversas atividades socioeconômicas (ARAME TALL; JEANNE Y. COULIBALY; MOUSTAPHA DIOP, 2018; ESCADA et al., 2021; ORDOÑEZ et al., 2022)

. Precipitação abaixo da média na estação de crescimento e/ou intensa na época da colheita tem grande potencial para a frustração de safras. Agricultura e recursos hídricos são particularmente afetados por chuvas excessivas ou secas, influenciando os sistemas de seguros agrícolas e de abastecimento humano/animal e pleno funcionamento industrial (OSGOOD et al., 2008; STAINFORTH, 2014; CEGLAR; TORETI, 2021; DARON; MILLER et al., 2021).

Para essa pesquisa, tem-se como objetivo avaliar as previsões subsazonais de precipitação do Meteo-France, em sua versão 7, para a área da Bacia Hidrográfica do rio Mundaú (BHM), entre os estados de Pernambuco e Alagoas, na região Nordeste do Brasil com até 5 meses de antecedência. As previsões do Meteo-France-System 7 (MFS7) foram avaliadas de acordo com scores (pontuações) determinísticas. Foi usada uma técnica de regionalização estatística, a Análise de Correlações Canônicas (ACC), para melhoria do desempenho das previsões do MFS7 na BHM, usando diferentes fontes de dados de precipitação para todos os municípios da BHM. O objetivo detalhado, a apresentação do referencial teórico, as descrições das fontes de dados de superfície, do modelo, da metodologia, assim como a descrição e discussão dos resultados e conclusões obtidas, são mostradas nos tópicos subsequentes.

1.1 OBJETIVO GERAL

Avaliar a destreza e viabilidade operacional das previsões climáticas mensais da precipitação acumulada com até cinco meses de antecedência na BHM do modelo MFS7 após aplicação de uma técnica de pós processamento estatístico.

1.2 OBJETIVOS ESPECÍFICOS

(a) validar os dados de precipitação estimados pelo Climate Hazards Group InfraRed Precipitation with Station data (CHIRPS) na área da BHM.

(b) quantificar as diferenças da destreza das previsões da precipitação mensal prevista pelo MFS7 antes e depois da aplicação da previsão por conjuntos.

2. REVISÃO BIBLIOGRÁFICA

2.1 Previsão Climática

As previsões de clima precisas e acuradas dão suporte ao planejamento de atividades de diversas esferas da sociedade (REBOITA et al., 2018). O prognóstico de características futuras das variáveis meteorológicas é o objeto de muitos estudos, e vários métodos são utilizados. Diante de um apropriado grau de precisão, é possível planejar futuras ações tendo como foco a sociedade como um todo (MOURA et al., 2020).

De acordo com Tucci; Leite; Dias, (2002), os prognósticos climáticos são realizados por métodos estatísticos ou através da simulação climática em computadores de alto desempenho com complexos modelos hidrodinâmicos dos processos atmosféricos.

Na previsão de tempo, deseja-se tomar ciência de como serão as condições atmosféricas nos próximos dias, já a previsão climática indica como uma dada estação do ano se comportará diante da média climatológica, mais quente ou mais fria etc., bem como a intensidade das anomalias em relação à média (YNOUE et al., 2017).

As previsões climáticas atendem a um período de, no mínimo, um mês, mas na maioria das vezes se estendem por períodos de três meses, tendo como objetivo a suavização da variabilidade intra-sazonal (RIBEIRO FILHO, 2009).

Os padrões e mecanismos globais responsáveis pela ocorrência de precipitação têm uma relação direta com a circulação atmosférica, a qual é determinada principalmente pela diferença de temperatura da superfície terrestre e dos oceanos e distribuição dos continentes (FERREIRA; MELLO, 2005).

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 surgir com a finalidade de prever as condições climáticas sazonais, 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 Organização Mundial de Meteorologia (OMM) designou centros de previsão com a responsabilidade obrigatória de gerar e entregar previsões sazonais (com cobertura global), incluindo informações de verificação associadas (COELHO et al., 2006). 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 pelo National Center for Environmental Prediction

(NCEP). Isso facilitou o acesso mundial aos dados de previsões sazonais baseadas em conjuntos de vários modelos (LEE et al., 2022).

O Brasil com suas dimensões continentais e consequente diversidade climática, necessita de uma rede de observações meteorológicas ampla, e de modelos de previsão de tempo e clima bem calibrados e parametrizados de acordo com as características próprias dos solos, vegetação, hidrografia, etc. ((LUIZ SILVA; BARRETO, 2016). Pode-se dizer que o Brasil acompanha o padrão dos Países desenvolvidos na geração e aplicação de metodologias e modelos que visam fornecer o que há de mais moderno para a produção de produtos para os serviços climáticos, possuindo, por exemplo, um modelo inteiramente desenvolvido pelo grupo de modelagem global do CPTEC/INPE: o Modelo Atmosférico Global Brasileiro - BAM (HERDIES et al., 2023).

Outras iniciativas podem e devem ser citadas, como o modelo de previsão climática puramente estatística desenvolvido e aplicado pelo Instituto Nacional de Meteorologia - INMET (LÚCIO et al., 2010), disponibilizado mensalmente em seu site para os usuários. O projeto EURO-BRazilian Initiative for Improving South American Seasonal Forecasts (EUROBRISA) fornece desde 2005 produtos de previsão climática regionalizados para toda a América do Sul provenientes de modelos europeus do European Centre for Medium-Range Weather Forecasts (ECMWF), MetOffice (Reino Unido) e Météo-France (França), em uma abordagem híbrida empírica que mescla as previsões desses modelos às advindas do uso da temperatura da superfície do mar (TSM) como principal elemento preditor das chuvas sazonais (COELHO et al., 2006; COELHO; COSTA, 2010).

No entanto, tais iniciativas não esgotam as possibilidades de implementação de melhorias às previsões de modelos dinâmicos por meio, por exemplo, de abordagens estatísticas que visam elevar o potencial preditivo desses modelos (DA ROCHA JÚNIOR et al., 2021).

2.2 Modelos Dinâmicos

Os resultados de vários modelos matemáticos que simulam a dinâmica da atmosfera são chamados de modelos de previsão numérica (modelos dinâmicos) (MARTINS; VASCONCELOS JÚNIOR, 2017). Segundo Ribeiro Filho (2009), eles resolvem um sistema complexo de equações matemáticas baseadas em leis físicas de modo a prever o estado futuro da atmosfera partindo de condições iniciais específicas. Suas equações matemáticas são as formas mais completas e complexas das equações dinâmicas e termodinâmicas.

Ainda de acordo com Ribeiro Filho (2009), a classificação dos modelos de previsão numérica se dá por sua escala espacial (global e regional). O modelo global possui resolução

da ordem de várias dezenas a poucas centenas de quilômetros, possuem o objetivo de identificar o comportamento geral da atmosfera sobre uma área extensa, no entanto, estes modelos são apenas capazes de identificar fenômenos meteorológicos de grande escala (ditos sinóticos). Já o modelo regional/local, possui resolução espacial típica de quilômetros a dezenas de quilômetros, conseguem identificar com maior detalhe o comportamento da atmosfera sobre uma região específica, sendo apropriados para identificar fenômenos meteorológicos de menor escala (ditos de mesoescala).

Ribeiro Filho (2009) destaca que os modelos globais se destinam a descrever movimentos atmosféricos sobre o planeta como um todo. São também denominados Modelo de Circulação Geral Atmosférico (MCGA) ou Modelo de Circulação Geral (MCG).

Os MCGA consistem em formulações matemáticas dos processos atmosféricos e das superfícies terrestre e oceânica. Estas formulações estão baseadas nos princípios físicos clássicos da hidrodinâmica (FERREIRA DA COSTA, 2005).

Ainda, segundo Ribeiro Filho (2009), tais modelos podem ser configurados para previsão de tempo ou para estudos climáticos. No tocante da previsão de tempo, o modelo é executado em uma escala temporal de dias (entre uma e duas semanas) objetivando 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.

Já os modelos regionais são aqueles cujo espaçamento de grade é menor do que aquele usado em modelos globais, o que permite a representação de fenômenos de mesoescala (RIBEIRO FILHO, 2009).

Em geral, esses modelos produzem prognósticos mais acurados do que os modelos globais, já que possuem melhor resolução horizontal e parametrizações físicas mais adequadas para resolver os processos atmosféricos de mesoescala (REBOITA et al., 2018).

2.3 Modelos Empíricos

As ferramentas estatísticas para suporte na previsão climática provindas de modelos dinâmicos, se mostram uma possibilidade promissora, principalmente em áreas onde os modelos dinâmicos disponíveis não apresentam resultados satisfatórios (HASTENRATH; WU; CHU, 1984).

Estes modelos não se baseiam nas equações físicas que governam o escoamento do fluido atmosférico, tão-somente constituem relações empíricas dentro de um conjunto de dados

experimentais conhecidos. Eles ajustam um conjunto de equações simultâneas sobre as séries temporais de forma experimental (DA ROCHA JÚNIOR et al., 2021).

Geralmente é necessário recorrer à análise multivariada quando se deseja ter informações acerca de um grupo de variáveis ou do conjunto total dos dados de uma região. Este conjunto de técnicas estatísticas é também utilizado para reduzir ao máximo o número de variáveis envolvidas em um problema com uma pequena perda de informações. Destaca-se como principais objetivos: reduzir a dimensão de interpretação de uma matriz de dados; investigar o comportamento espacial e temporal das variáveis consideradas e obter grupos homogêneos das variáveis (OSMAN; COELHO; VERA, 2021).

Na análise multivariada, existem muitas técnicas de manipulação de dados climatológicos, destaca-se: a Regressão Linear Múltipla (RLM), a Análise de Componentes Principais (ACP), a Análise de Correlação Canônica (ACC) entre outras (MANZANAS et al., 2018).

2.3.1 Regressão Múltipla

A Regressão Múltipla é um dos numerosos modelos estatísticos explanatórios causais referentes ao tratamento de séries temporais de dados. Sua base estatística advém da Regressão Linear, que se restringe a duas variáveis e a apenas uma equação funcional do primeiro grau ($Y = a + bX$) de ajustamento (MERTLER; VANNATTA, 1984).

A análise de Regressão Múltipla é uma metodologia estatística de previsão de valores de uma ou mais variáveis de resposta (dependentes) através de um conjunto de variáveis explicativas (independentes). Esta metodologia pode ser utilizada também para a avaliação dos efeitos das variáveis explicativas como previsoras das variáveis de resposta (OTTO, 1999).

Sua aplicação é de maneira especial importante por permitir que se estime o valor de uma variável com base num conjunto de outras variáveis. Quanto mais significativo for o peso de uma variável isolada, ou de um conjunto de variáveis explicativas, tanto mais se poderá afirmar que alguns fatores afetam mais o comportamento de uma variável de resposta especificamente procurada, do que outros (RIBEIRO, 2015).

O formato geral da equação de Regressão Linear Múltipla é apresentado na Equação 1.

$$Y = a + b_1X_1 + b_2X_2 + \dots + b_KX_K \text{ (Equação 1)}$$

Onde:

Y - é a variável dependente;

a - corresponde a um coeficiente técnico fixo, a um valor de base a partir do qual começa Y;

b_k - corresponde aos coeficientes técnicos atrelados às Variáveis Independentes; e

X_k - as Variáveis Independentes.

2.3.2 Análise de Componentes Principais (ACP)

A Análise de Componentes Principais (ACP) transforma uma série de variáveis originais dentro de uma série menor de combinações lineares que explicam a maior parte da variância da série original de dados. O objetivo da ACP é determinar os valores, ou seja, os Componentes Principais (CP) de modo a explicar o quanto da variância total da série pode ser esclarecido com poucos desses fatores (ROSSI, 2018).

A Análise de Componentes Principais (ACP) é um método matemático cujo objetivo é transformar um conjunto de variáveis originais em outro conjunto chamado de Componentes Principais. Os componentes apresentam as seguintes características: cada componente principal é uma combinação linear de todas as variáveis originais, os componentes são independentes entre si e retém, em ordem de estimação, o máximo de informação relacionada à variação dos dados originais. A análise permite a redução dimensional de um alto número de variáveis, a partir da rotação do eixo original dos dados, transformando-os em um novo sistema de coordenadas (MARONNA, 2011).

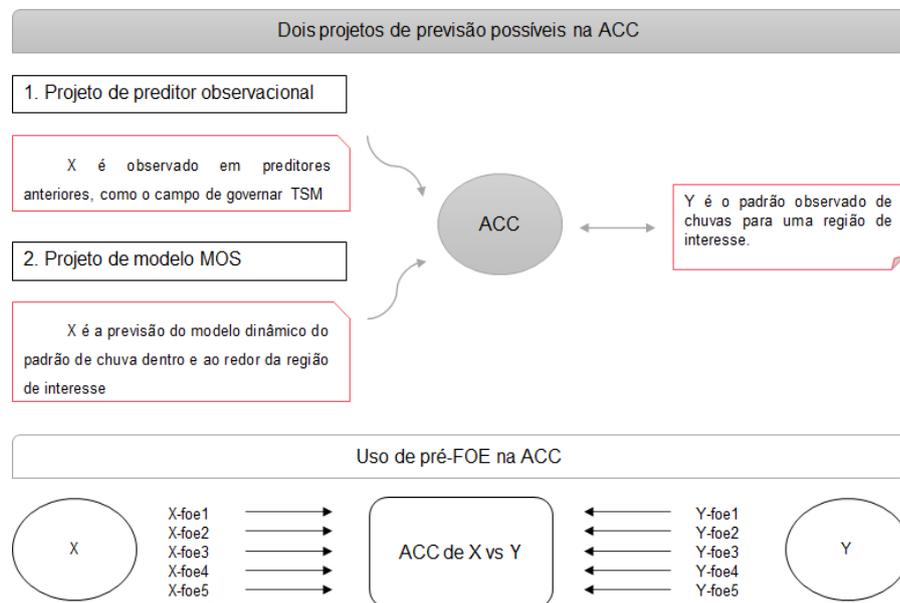
2.3.3 Análise de Correlações Canônicas (ACC)

A ACC é um procedimento estatístico multivariado que permite o exame da estrutura de relações existentes entre dois grupos ou conjuntos de variáveis (PROTÁSIO et al., 2012).

A metodologia da ACC tem sido usada de duas maneiras conforme apresentado por Barnston & Tippett (2017). O primeiro modo é um modelo de previsão puramente estatístico que relaciona padrões de anomalias em observações recentes (por exemplo, anomalias na temperatura da superfície do mar) a padrões de anomalia climática em um trimestre subsequente (por exemplo, anomalias de precipitação) com base em um período extenso de hindcast, sem envolvimento de nenhum modelo dinâmico (BARNETT; PREISENDORFER, 1987; BARNSTON, 1994). A outra maneira de se utilizar ACC, é relacionar os dados brutos da previsão de precipitação com as observações correspondentes em um período de hindcast.

Assim como descrito em Barnston & Tippett (2017), uma pré-ortogonalização é realizada utilizando análise de funções ortogonais empíricas (FOE), também denominada por Componentes Principais, de forma separada aos *hindcasts* do modelo (variável X, ou preditor) e nas correspondentes observações (variável Y ou preditando), e o conjunto das séries temporais de componentes principais de maior importância dessas EOFs é usada como entrada para a ACC (Figura 1). Esta metodologia reduz o número de variáveis usadas pela ACC preservando padrões de variabilidade mais coerentes (BARNETT; PREISENDORFER, 1987).

Figura 1 – Domínio do preditor X e do preditando Y (acima) e (abaixo) processo de redução do número de variáveis (pontos de grade) para obter séries independentes (ortogonais entre si).



Fonte: Adaptado de Barnston & Tippett (2017).

De acordo com Rustiana et al., (2017), a ACC é um método para encontrar a melhor combinação linear entre dois conjuntos de dados multivariados que maximizam o coeficiente de correlação entre eles. A ACC se concentra apenas na correlação entre uma combinação linear das variáveis em um conjunto e combinação linear das variáveis em outro conjunto. A ideia é primeiramente determinar o par de combinações lineares com a maior correlação. Em seguida, determina o par de combinações lineares tendo a maior correlação entre todos os pares não correlacionados com o inicialmente par selecionado, e assim por diante. Os pares de combinações lineares são chamados de variáveis do canônico, e suas correlações são chamadas de correlação canônica. Isto é particularmente útil para determinar a relação entre as medidas de critério e o conjunto de revisões de seus fatores explicativos (HAMAKAWA, 2002).

Envolve esta técnica, primeiro, a redução das dimensões dos dois conjuntos de dados multivariados por projeção, e segundo, o cálculo da relação (medida pela correlação coeficiente) entre as duas projeções dos conjuntos de dados (LOESCH, 2012). A ideia básica por trás da previsão com ACC é simples: são construídas regressões lineares simples que relacionam o preditivo variáveis canônicas (x) para as variáveis canônicas predictoras (y).

Os resultados encontrados por Ribeiro Filho (2009), sugerem que o uso de ACC na previsão climática sazonal proporciona bons resultados tanto diretamente como modelo empírico quanto associada a modelos dinâmicos. O trabalho tinha como objetivos: 1) aplicar um modelo empírico de correlações canônicas para a previsão sazonal de anomalias de

precipitação e 2) utilizar o modelo de correlações canônicas como corretor dos resultados de um modelo dinâmico utilizado na Fundação Cearense de Meteorologia e Recursos Hídricos na previsão climática sazonal e para agregar à informação gerada por esse modelo a informação da TSM propriamente dita compondo um modelo de previsão híbrido dinâmico-empírico.

2.4 Downscaling estatístico

Os métodos de downscaling são subdivididos nas categorias dinâmicos e estatísticos, e tem o propósito de colmatar o problema de baixa resolução dos Modelos Climáticos Globais e Modelos Climáticos Regionais.

O downscaling dinâmico é uma abordagem numérica que consiste na utilização de modelos globais ou reanálise como forçadores de modo a obter simulações de dados mais detalhadas para uma região particular. Já o downscaling estatístico utiliza modelos estatísticos simples, de modo a estabelecer a relação estatística entre variáveis de grande escala e variáveis locais.

Hanssen-Bauer et al., (2005), avaliaram cenários climáticos ao longo da Escandinávia, concluindo que comparações com resultados de modelos climáticos globais e regionais indicam que tanto a modelagem regional quanto o downscaling estatístico agregam valor aos resultados dos modelos globais. De acordo com os autores, na maioria dos estudos escandinavos, os métodos Regressão Linear Múltipla e Análise de Correlação Canônica foram aplicados em combinação com um passo a passo processo de triagem para escolher o melhor conjunto de preditores.

A ACC é aplicada como método de downscaling e Model Output Statistics (MOS) em inúmeros trabalhos (MANZANAS et al., 2018). Wu; Jiang; Ma, (2016) utilizaram a ACC para downscaling de projeções de precipitação diária para a bacia do rio Yangtze-Huaihe, China.

Tiwari et al., (2019) compararam downscaling proveniente de métodos estatísticos (ACC) e métodos dinâmicos (Modelo Regional) para o norte da Índia e concluiu que os dois métodos melhoram significativamente a previsão dos MCGs.

2.5 CHIRPS

Atualmente, o avanço tecnológico possibilita o uso de sensoriamento remoto para estimativas de chuvas, tornando-se boas alternativas e melhores opções para preencher as lacunas existentes (GELETA; DERESSA, 2021). De acordo com Fagundes et al., (2020), a utilização de produtos provindos de satélites meteorológicos e radar podem ser uma ferramenta

útil para suprir a falta de informação convencional e subsidiar a análise da ocorrência espacial e temporal de elementos climáticos.

Os produtos baseados em satélite, ajudam a solucionar a limitação provinda da baixa densidade espacial da rede de pluviômetros em solo (SOBREIRO; STREHER; SILVA, 2017). As pesquisas com dados de satélite e radar têm se destacado, por causa da democratização dos dados meteorológicos por meio de processos de aquisição destes, através de downloads de diversas plataformas de grandes centros mundiais de pesquisa (DEE; FASULLO; SHEA, 2016).

O CHIRPS (Climate Hazards Group InfraRed Precipitation with Stations) é um conjunto de dados de chuva quase global desenvolvido pelo United States Geological Survey (USGS) e pelo Climate Hazards Group at the University of California, Santa Barbara (UCSB). O produto CHIRPS possui uma resolução espacial de 0,05°, ou aproximadamente 5 km, próximo ao equador, cobertura geográfica de 50°S a 50°N, com dados a partir de 1981 até os dias atuais e é disponibilizado em conjuntos de dados diários e mensais (COSTA et al., 2019).

As fontes de dados que são utilizadas para produzir os produtos de chuvas estimadas pelo CHIRPS são: The Climate Hazards Center's Precipitation Climatology (CHPClim); observações de satélite com espectroscopia de infravermelho termal (TIR), geoestacionária quase global da National Oceanic and Atmospheric Administration (NOAA); Produtos do Centro de Previsão Climática (CPC) e do National Climatic Data Center (NCDC); Coupled Forecast System da NOAA, versão 2 (CFSv2) e dados observacionais de estações meteorológicas (FUNK et al., 2015).

No contexto do Nordeste brasileiro, o padrão sazonal de precipitação foi bem representado pelos dados obtidos por sensoriamento remoto por meio do CHIRPS (DOS SANTOS; CUNHA; RIBEIRO-NETO, 2019).

No estado de Alagoas, LYRA; FREITAS e SANTIAGO, (2020) avaliaram as estimativas de precipitação com o auxílio do CHIRPS e concluíram que estes dados podem ser utilizados para extrair informações espaciais a respeito da precipitação, uma vez que apresentam boa qualidade e valores próximos do observado em estações meteorológicas de superfície.

2.6 Clima e Variabilidade da Precipitação no Nordeste do Brasil

De acordo com Commar (2020), o regime de precipitação no NEB pode ser classificado em três: (I) Sua porção sudoeste possui o período chuvoso entre outubro e fevereiro que se deve às frentes frias advindas do sul do Brasil e a influência do El Niño-Oscilação do Sul (ENOS),

região esta onde se localiza o Oeste da Bahia; (II) A porção ao norte do NEB tem o período chuvoso entre fevereiro e maio, associado ao deslocamento para o sul da ZCIT; além disso é caracterizada por forte variabilidade interanual, onde ocorrem grandes secas; (III) A porção leste do NEB é conhecida como Zona da Mata e seu período chuvoso se dá entre os meses de abril e agosto, e sua ocorrência deriva do contraste de temperatura entre o oceano e continente, com chuvas predominantemente orográficas.

O clima do NEB é fortemente impactado por três mecanismos climáticos: El Niño Oscilação Sul (ENOS), Zona de Convergência Intertropical (ZCIT) e efeitos de frente fria (LAUX et al., 2021).

Em um estudo pioneiro, WALKER (1928) documentou uma notável coincidência do aquecimento anômalo das águas superficiais no Pacífico equatorial e as secas do nordeste do Brasil (NEB).

Desde então, muitos estudos que buscam um melhor entendimento dos mecanismos que causam as anomalias climáticas sobre o NEB têm focalizado no papel que o fenômeno ENOS exerce em tais anomalias (KAYANO; ANDREOLI, 2007).

O clima do Nordeste tem como principais forçantes a TSM nos Oceanos Pacífico e Atlântico. A variabilidade nessas forçantes impulsiona variação espacial e flutuações nos acumulados de precipitação (MARTINS; VASCONCELOS JÚNIOR, 2017).

A componente oceânica do ENOS caracteriza-se pela ocorrência de TSM no Pacífico equatorial central e leste anormalmente positivas (El Niño) em uma fase e negativas (La Niña) na fase oposta, dinamicamente relacionada à Oscilação Sul, que se manifesta como uma gangorra barométrica com centros de ação na Indonésia e no Pacífico Sudeste (RASMUSSEN; CARPENTER, 1982).

Da Silva, (2009), estudou as escalas temporais da variabilidade pluviométrica na Bacia Hidrográfica do Rio Mundaú (BHM), onde foram utilizados dados de precipitação da bacia hidrográfica do rio Mundaú, nos Estados de Alagoas e Pernambuco, obtidos da Agência Nacional de Águas e Saneamento Básico (ANA), de 1955 a 1991. As análises foram feitas para três regiões desta bacia: Alto Mundaú (AM), Médio Mundaú (MM) e Baixo Mundaú (BM).

No trabalho de Kayano et. al., (2010), verificou-se para a BHM, através da análise de ondaletas, que principalmente a variabilidade interanual ligada ao ciclo de ENOS, a variabilidade decenal, bem como a variabilidade interanual curta, influencia na variabilidade pluviométrica local.

3. MATERIAL E MÉTODOS

3.1 Caracterização da Área de Estudo

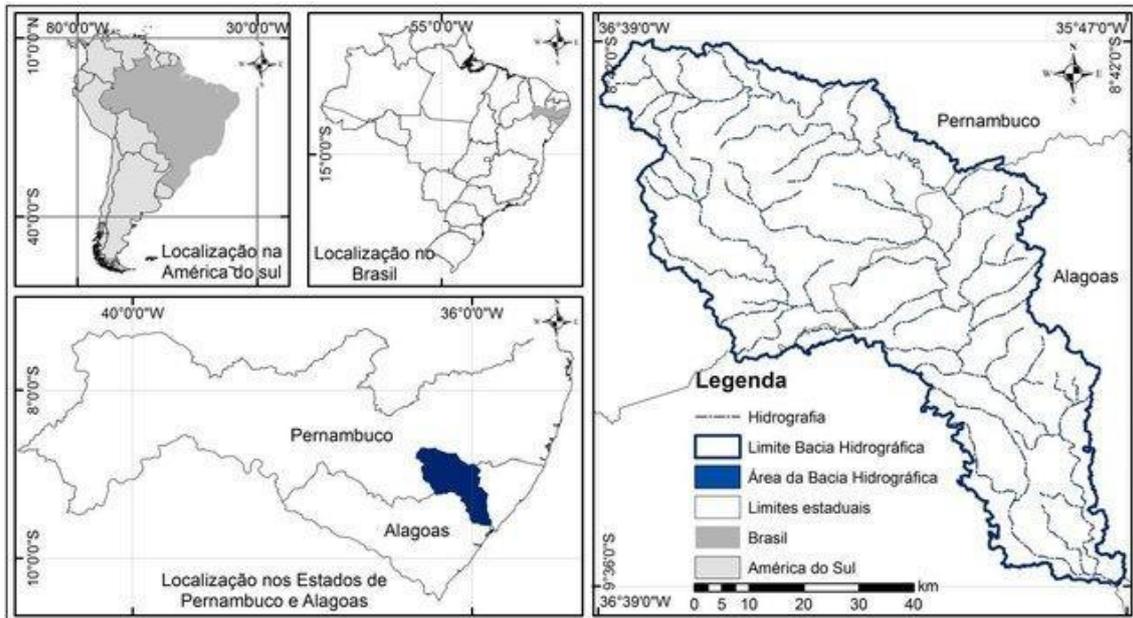
O estudo foi realizado na Bacia Hidrográfica do rio Mundaú (BHM), conforme Figura 2. O rio Mundaú nasce no agreste pernambucano no município de Garanhuns e deságua em Alagoas na laguna Mundaú, Complexo Estuarino Lagunar Mundaú-Manguaba (CELMM). O rio principal possui uma extensão de aproximadamente 140 km, com uma declividade média de 3,75 m/km e tempo de concentração médio de 1,57 dias (FRAGOSO JÚNIOR et al., 2010). A BHM com uma área de aproximadamente 4.105 km² abrange 36 municípios, 17 pernambucanos (53% de área) e 19 municípios alagoanos (47% de área). A importância para os estados deve-se principalmente: a) ao abastecimento de diversos reservatórios e barragens localizadas na cabeceira (região semiárida); b) ao abastecimento de água para irrigação de diversos cultivos (agricultura); c) preservação do CELMM, um dos complexos lagunares mais produtivos do Brasil (SOUZA et al., 2004).

Monte (2013) relatou os grandes eventos de cheia na BHM que provocaram prejuízos e catástrofes (e.g. cheias de 1914, 1941, 1969, 1988, 1989, 2000 e 2010). Posterior a este estudo, destacam-se os eventos de 2017 e 2022.

A geologia da BHM é determinada no alto e no médio pelo Maciço Pernambuco-Alagoas, baseado em rochas cristalinas (i.e. de formação ígnea ou metamórfica), com menos capacidade de infiltração, e no baixo curso está situada a Bacia Sedimentar Sergipe-Alagoas, ocupando uma pequena parte da BHM, tendo maior capacidade de infiltração (MONTE, 2013).

Costa (2014) destaca que a parte alta da Bacia está inserida no bioma Caatinga, tendo aspecto climático semiárido, estando inclusive no Polígono das Secas, e o bioma Mata Atlântica na parte baixa estende-se até a foz com clima Tropical.

Figura 2 – Localização da Bacia Hidrográfica do rio Mundaú (BHM).



Fonte: Duarte et al., (2016).

3.2 Dados de Chuva Estimados pelo CHIRPS

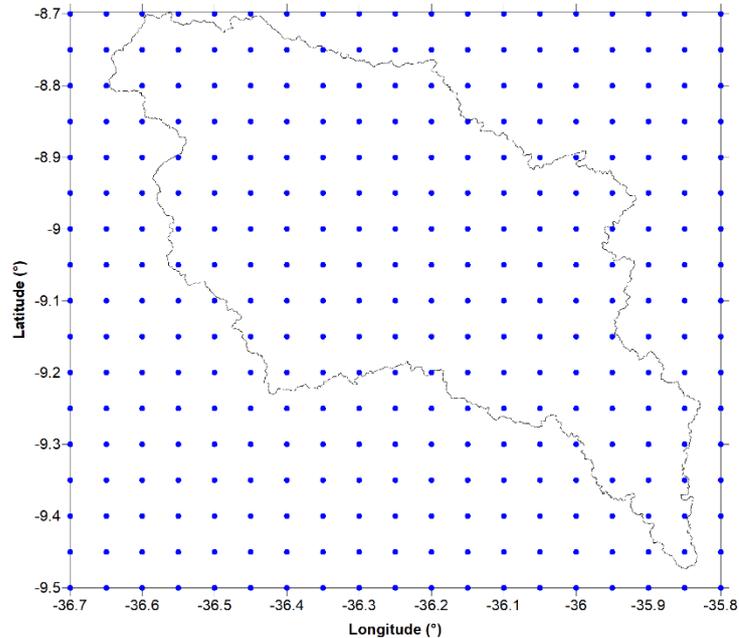
Os dados CHIRPS vêm de esforços de instituições dos EUA para mapear a precipitação, especialmente em áreas com poucas observações de superfície e em áreas de terreno complexo, como cadeias de montanhas (FUNK et al., 2015). O CHIRPS usa todos os dados de uma rede de observações de superfície para construir uma grade de alta resolução, juntamente com estimativas de precipitação baseadas em observações infravermelhas de duração de nuvens frias (HUFFMAN et al., 2007).

As estimativas por satélites são combinadas com as observações de superfície do Sistema Global de Telecomunicações (GTS) da OMM e são reamostradas em uma grade regular de $0,05^\circ$, levando em conta as características fisiografias da superfície, de 1981 até o presente, limitada entre as latitudes de 50°N a 50°S .

Devido à baixa disponibilidade de dados observados em estações meteorológicas e postos pluviométricos na BHM, utilizamos o CHIRPS para extrair 323 pontos a cada $0,05^\circ$ de distância entre eles, de acordo com a Figura 3. Esses dados foram extraídos em séries temporais de precipitação diária, e acumuladas mensalmente, de janeiro de 1981 a dezembro de 2020. Esse período de dados permitiu validar os dados do CHIRPS na BHM versus os dados de alguns postos pluviométricos disponibilizados pela ANA na BHM, além de permitir a calibração das previsões do MFS7 entre 1983-2016, e avaliar a performance das previsões desse modelo calibrado para a BHM para o ano de 2020.

Os dados do CHIRPS estão disponíveis em formato netcdf. Para geração das séries temporal em formato ascii, foram desenvolvidos e utilizados scripts em linguagem R na versão 4.0.3.

Figura 3 – Distribuição espacial dos pontos extraídos do CHIRPS na BHM, com resolução espacial de 0,05°.



Fonte: autor.

3.3 Climatologia na BHM

Para a determinação da climatologia e das tendências observadas nos extremos climáticos em uma determinada região é ideal que se tenha longas séries de dados diários das variáveis a serem analisadas (SILVA; DERECZYNSKI, 2014).

A BHM é influenciada por diferentes sistemas sinóticos a mecanismos de grande escala, que proporcionam eventos de secas ou enchentes (DA SILVA, 2009). O período seco ocorre entre setembro e fevereiro e o úmido de março a agosto, com concentração de 70% do regime pluviométrico anual, sendo que 50% do total precipitado anual entre maio e julho (ALVES, 2016).

De acordo com Kayano. et al., (2010), o principal aspecto sazonal é que a quadra chuvosa se estende de abril a julho no Médio Mundaú (MM) e Baixo Mundaú (BM), enquanto no Alto Mundaú (AM) o período chuvoso estende-se de março a julho. Já os meses mais secos para o BM e MM são de outubro a janeiro enquanto no AM, de setembro a dezembro.

Segundo (MEDEIROS, 2020), a classificação climática de Köppen, é a mais utilizada em todo o mundo, por critérios geográficos e climáticos. Conforme essa classificação, o clima da BHM, se mescla entre os tipos: As (clima tropical com estação seca de verão), Am (clima

de monção), Csa (clima temperado húmido com verão seco e quente) e Csb (clima temperado húmido com verão seco e temperado), com predominância do tipo As sobre os demais (DUBREUIL et al., 2018).

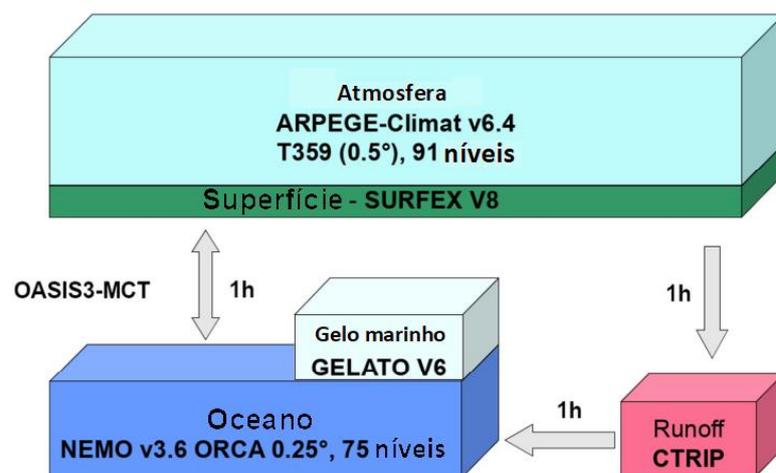
Neste trabalho, foi empregado um código em linguagem R para mapear a climatologia da BHM, adotando o período de 1981 a 2020 como referência para a caracterização climatológica da bacia. No entanto, para análise dos hindcasts do MFS7, a climatologia foi combinada ao período das previsões retrógradas de 1993 a 2016. Esse período foi adotado porque o modelo da Meteo-France usado para validação para a previsão climática da precipitação na área da bacia fornece um *hindcast* 1993-2016, e saídas de previsões de períodos recentes.

3.4 Meteo-France - System 7

A Météo-France, agência francesa de Meteorologia, está envolvida em atividades de previsão sazonal desde o final da década de 1990, com um centro imbuído de desenvolver modelos para previsão numérica de tempo e clima e para projeções futuras de mudanças climáticas: o Centre National de Recherches Météorologiques (CNRM). Seu sistema de previsão sazonal evoluiu através do desenvolvimento de várias versões consecutivas, incluindo os componentes do GCM acoplado e novas técnicas de inicialização e geração de previsões por conjuntos (MÉTÉO-FRANCE; BATTÉ, 2019).

O MFS7 possui quatro conjuntos de modelagem que são acoplados pelo sistema OASIS-MCT (Model Coupling Toolkit) versão 3.0 (LARSON; JACOB; ONG, 2005), para trocas dinâmicas entre os campos de cada modelo, quando precisam de interação entre si (Figura 4).

Figura 4 – Componentes do modelo CNRM-CM do sistema de previsão sazonal.



Os quatro componentes independentes do MFS7 são o atmosférico (ASPERGE), o oceânico (NEMO), o de superfície terrestre (SURFEX), um de escoamento por rios (ISBA-CTIP) e o de gelo marinho (GELATO). O MFS7 se utiliza de perturbações estocásticas na dinâmica e condições iniciais com a técnica de nudging e gerar membros do conjunto (42). A assimilação de dados observados do modelo se dá a cada 6 horas e são provenientes da reanálise ERA5, com correção suavizada de vieses pelo cálculo das anomalias assimiladas em relação à climatologia do modelo (HERSBACH et al., 2020). A seguir, descrição básica dos componentes do modelo.

3.4.1 Modelo atmosférico ASPERGE V6.4

A versão climática deste modelo foi projetada para experimentos de mudanças climáticas e previsões sazonais (DÉQUÉ et al., 1994). O MFS7 usa esquemas de parametrização física desenvolvidos para a versão 6 do modelo CRRM-CM (DECHARME et al., 2019), chamados de "física prognóstica", baseados na suposição de que os termos diabáticos são calculados para todas as colunas atmosféricas independentemente, mas com troca horizontal de variáveis prognósticas como energia cinética turbulenta, velocidade convectiva vertical, água sólida e líquida em diferentes estados (nuvem, precipitação intensa e convecção). Essas variáveis são advectadas e memorizadas durante as simulações (CUXART; BOUGEAULT; REDELSPERGER, 2000; LOPEZ, 2002; GUEREMY, 2011). Nessa versão uma nova formulação do fluxo de momento da superfície devido a orografia foi introduzida (BELJAARS; BROWN; WOOD, 2004). Uma apresentação detalhada das equações desse modelo está disponível na página do National Centre for Meteorological Research.

3.4.2 Modelo oceânico NEMO V3.6 e modelo de gelo marinho GELATO V6

O NEMO (Nucleus for European Modeling of the Ocean) é um modelo de equações primitivas adaptado à circulação oceânica regional e global, flexível para o estudo do oceano e de suas interações com outros componentes do sistema climático terrestre em uma ampla gama de escalas espaço-temporais. As variáveis prognósticas são o campo de velocidade tridimensional, temperatura e altura não linear da superfície do mar e salinidade. Na direção horizontal, o modelo usa uma grade ortogonal curvilínea e na direção vertical, uma coordenada z completa ou parcial, coordenadas ou uma mistura das duas coordenadas. A distribuição das variáveis é uma grade tridimensional do tipo Arakawa C. Várias opções físicas estão disponíveis para descrever a física oceânica. Dentro do NEMO, o oceano é conectado com um modelo de gelo marinho (GELATO V6) e, através do acoplador OASIS, com o modelo

atmosférico ARPEGE V6.4. Uma apresentação detalhada do NEMO está apresentada em Salas Mélia (2002).

3.4.3 Modelo de superfície terrestre Surfex V8 e modelo de escoamento fluvial CTRIP

Surfex (Surface Externalisée, em francês) é uma plataforma de modelagem de superfície desenvolvida pela Météo-France em cooperação com a comunidade científica. O Surfex é composto de vários modelos físicos para a superfície natural de terra, áreas urbanizadas, lagos e oceanos. Também simula processos químicos e de superfície de aerossóis e pode ser usado para assimilação de variáveis de superfície e próximas à superfície. O Surfex possui seus próprios procedimentos de inicialização e pode ser usado em modo autônomo e acoplado a um modelo atmosférico. No Surfex, cada grade do modelo é representada por quatro tipos de superfície: mar ou oceano, corpos d'água (lagos, ...), áreas urbanas e superfície natural (solo e vegetação). Cada tipo de superfície é modelado com um modelo específico da superfície e o fluxo total da grade resulta da soma dos fluxos individuais ponderados por suas respectivas frações.

Mais detalhes sobre a versão mais recente do Surfex e os modelos de escoamento da superfície terrestre e fluvial ISBA-CTRIP podem ser encontradas nos trabalhos de (VOLDOIRE et al., 2017; DECHARME et al., 2019).

3.4.4 Precipitação do MFS7

Desde início dos anos 2010 há um esforço global para disponibilizar a sociedade não apenas produtos de previsão sazonal, mas os arquivos gerados pelos modelos, para que possam ser melhor analisados em qualquer região do Planeta, a depender do interesse de uma pesquisa. Esse esforço foi iniciado pela criação do NMME (North American Multi-Model Ensemble), que em 2011 disponibilizou pela primeira vez as saídas brutas de previsões climáticas de modelos norte-americanos de forma frequente e padronizada (KIRTMAN et al., 2014). Esse projeto evoluiu e hoje a Europa também segue a mesma iniciativa, a exemplo do ECMWF, e de modelos específicos de alguns Países como Itália, Alemanha, França e do Reino Unido.

Em uma parceria com o CPC, a Universidade de Columbia, responsável por disponibilizar as versões do software CPT, incluiu uma funcionalidade nas versões mais recentes em que é possível baixar os dados das previsões de vários modelos diretamente do software, notadamente a partir de sua versão 17. O MFS7 fornece um conjunto completo de prognósticos passados de 1983 a 2016 de até cinco meses/trimestres desde o mês de sua inicialização. São estes *hindcasts* que podemos utilizar para a calibração de modelos e para

estudos aplicados. Associados aos *hindcasts*, pode-se baixar as previsões em tempo real do MFS7 a partir de 2017. São disponibilizadas três variáveis: a temperatura da superfície do mar, a temperatura média a 2 metros e a taxa de precipitação em milímetros por dia, em uma resolução espacial de 1° x 1° de latitude/longitude, para a média de todos os membros do conjunto.

Os dados estão disponíveis em dois formatos, binário e ascii. Nessa pesquisa a atividade inicial foi baixar todos os arquivos de *hindcast* e de prognósticos do MFS7. Essa atividade nos informa que, cada um dos doze meses do ano possui 5 *hindcasts*, ou seja, para 1 ano tem-se 60 *hindcasts*, o que quer dizer que o mês de junho, por exemplo, tem um *hindcast* mensal de janeiro a maio.

3.5 Software Climate Predictability Tool (CPT)

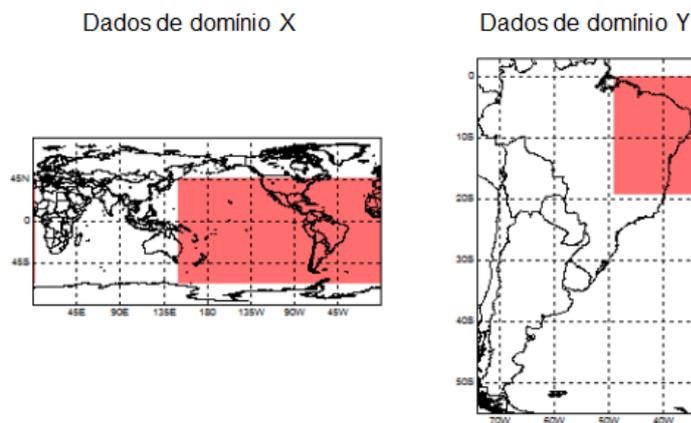
Para aplicar a Análise de Correlações Canônicas (ACC) foi utilizado o software *Climate Predictability Tool* (CPT), fornecido pelo *International Research Institute for Climate and Society* (IRI). O CPT é projetado para gerar ou pós-processar previsões climáticas sazonais. O CPT é uma ferramenta fácil de usar com versões para Windows e Linux, com código fonte em linguagem Fortran 90. O software foi desenvolvido inicialmente para permitir que previsores em Serviços Meteorológicos Nacionais na África para produzir previsões sazonais atualizadas para seu país, e para fornecer maior consistência nas contribuições para os Fóruns Regionais de Perspectivas Climáticas para facilitar a construção de consenso, mas o CPT tem sido usado amplamente.

De acordo com (HOSSAIN et al., 2017), existem duas abordagens principais para gerar previsões sazonais: usando modelos de grande escala de atmosfera global, conhecidos como modelos de circulação geral (GCMs), ou usando uma abordagem para relacionar o clima sazonal com as mudanças nas temperaturas da superfície do mar, como aqueles associados ao El Niño ou a outros preditores. No primeiro caso, são feitas previsões para grandes áreas, e muitas vezes não são muito relevantes para locais específicos. Além disso, por causa da escala grosseira em que os GCMs operam, a geografia nos modelos é muitas vezes distorcida e, portanto, localizações geográficas podem ser deslocadas. Essas saídas do GCM, portanto, precisam ser ajustadas para que possam ser aplicadas a nível local. A ferramenta CPT foi projetada para realizar ambas as formas de previsão, ou seja, *downscaling* da saída do GCM e previsões puramente estatísticas.

A variável preditora utilizada foi a precipitação provinda do CHIRPS. Foi empregado um *hindcast* de 23 anos (1993 a 2016). Na ACC, foram relacionados os dados brutos da previsão

de precipitação proveniente do MFS7 com as observações correspondentes em um período de hindcast do CHIRPS. O domínio preditivo para a BHM foi projetado para ser maior que o NEB, enquanto o domínio preditor tentou abranger uma área grande suficiente para contemplar a maior parte dos fenômenos de baixa frequência que atuam sobre a variabilidade climática do NEB. As áreas do preditando e do preditor foram escolhidas baseadas nos resultados alcançados no trabalho de Barnston & Tippet (2017) ao utilizar as referidas dimensões de território.

Figura 5 – Domínio usado no CPT.



Fonte: autor.

O CPT aplica o pré-processamento de Função Ortogonal Empírica (FOE ou EOF) antes do método ACC e depois estima o modelo por um processo de validação cruzada. Ou seja, o conjunto de dados (hindcast) para estimativa do modelo é particionado em subconjuntos mutuamente exclusivos que alguns serão usados para estimar o modelo e o conjunto restante para validação. O método de validação cruzada se caracteriza por esse processo de treino e validação se repetindo até que todos os conjuntos tenham sido usados em algum momento para validar o modelo sem ter sido usado para treiná-lo. Esse processo permite a ótima validação de um modelo utilizando todos os dados disponíveis para estimar os parâmetros (PICARD; COOK, 1984; STONE, 1978; BROWNE, 2000). É muito útil para validação de previsões climáticas por ser ter séries de dados muito curtas para validar.

3.6 Avaliação do desempenho

3.6.1 Coeficiente de Correlação de Pearson

Em probabilidade e estatística, correlação, dependência ou associação (dada pela Equação 1) é qualquer relação estatística entre duas variáveis e correlação é qualquer relação

dentro de uma ampla classe de relações estatísticas que envolva dependência entre duas variáveis, (MARTINS; VASCONCELOS JÚNIOR, 2017).

Para mensurar a associação entre as variáveis previstas e observadas com um único valor, utilizamos o coeficiente de correlação de Pearson. Quanto mais o valor de r estiver perto da unidade, maior é a associação entre duas variáveis.

No presente estudo, trata-se da associação entre a chuva observada e aquela estimada via previsão climática. O coeficiente de correlação é definido como a covariância das variáveis ($Cov(o, p)$) dividida pelo produto de seus desvios padrões ($\sigma(o, p)$).

$$r_{o,p} = \frac{Cov(o, p)}{\sigma(o, p)} \quad (\text{Equação 2})$$

Como forma de auxiliar a 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 1. Classificação das faixas de correlação e definição da relação entre os dados simulados por um modelo e os dados observados. Fonte: Devore (2006).

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

Para garantir que o valor de r realmente expresse a concordância entre observações e simulações, será utilizado o teste paramétrico t-Student 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 , do qual se obtém o valor do coeficiente de correlação, r , é igual ou maior que 6, então o valor de t é dado por (Equação 3):

$$t = \frac{r}{\sqrt{\frac{(1-r^2)}{(N-2)}}} \quad (\text{Equação 3})$$

A equação 3 é uma distribuição para t com $N-2$ graus de liberdade. Aplicar esta 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 crítico de correlação (r_c), que é um valor para o qual se aceita ou não a hipótese estatística de haver correlação entre os dados simulados e observados, r_c é dado por:

$$r_c = \sqrt{\frac{t^2}{(N-2) + t^2}} \quad (\text{Equação 4})$$

3.6.2 Erro Médio Absoluto (MAE)

Indica a magnitude média dos erros em um conjunto de previsões, independentemente de sua direção (WILLMOTT; MATSUURA, 2005). 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: se não for obtido um valor absoluto, o *MAE* passa a ser *MBE* (Mean Bias Error, ou bias (viés)) e neste caso serve de parâmetro para medir a tendência média do modelo. O *MBE* transmite informações úteis, mas deve ser interpretado com cautela, pois os erros positivos e negativos tendem a se anular em amostras imparciais, por isso, não o utilizaremos como uma das medidas de destreza da previsão determinística.

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_i - O_i| \quad (\text{Equação 5})$$

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

3.6.3 Erro quadrático médio (RMSE)

É uma pontuação quadrática que também mede a magnitude média do erro, (WILLMOTT; MATSUURA, 2005). É a raiz quadrada da média das diferenças ao quadrado entre a previsão e a observação real.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad (\text{Equação 5})$$

Comparação entre *MAE* e *RMSE*:

Semelhanças: Tanto o *MAE* quanto o *RMSE* expressam o erro médio de previsão do modelo em unidades da variável de interesse. Ambas as métricas podem variar de 0 a ∞ e são indiferentes à direção dos erros. Essas são pontuações orientadas negativamente, 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.

3.6.4 Diagramas de Taylor

Os diagramas de Taylor foram criados para esquematizar graficamente qual sistema de valores simulados ou modelados mais se aproxima do valor real (TAYLOR, 2001). Esse diagrama fornece em um só gráfico o resumo de três importantes parâmetros estatísticos da observação e simulações: o desvio padrão, a correlação e o erro médio quadrático centralizado entre todos os dados observados (*o*) e previstos (*p*). Para descrever a qualidade do modelo, uma das estatísticas mais usadas é o RMSE, cujo RMSE centralizado corresponde a uma expansão do RMSE (Eq. 6):

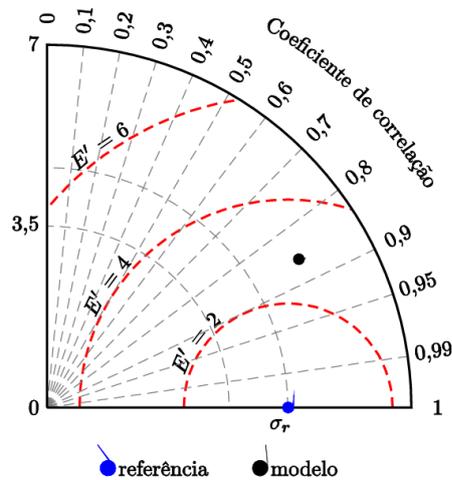
$$RMSE^2 = \sigma_p^2 + \sigma_o^2 - 2\sigma_p^2\sigma_o^2 \cdot r \quad (\text{Equação 6})$$

onde são os desvios-padrão dos dados previstos e observados, e *r* o coeficiente de correlação. Essa equação parte da similaridade com a equação da lei dos cossenos, que relaciona o ângulo interno de um triângulo com seus lados:

O diagrama de Taylor é construído com $\frac{1}{2}$ de círculo (quando se observam correlações negativas) ou $\frac{1}{4}$ de círculo (quando não se observam correlações negativas). Os eixos *x* e *y* tem as medidas do desvio-padrão, com o $\sigma(o)$ no eixo *x*, $\sigma(p)$ representa a distância radial da origem, e o azimute é proporcional a *r*.

O valor de *R* (correlação) dos dados observados e estimados pelo método é o azimute do ponto. A correlação do ponto de referência com ele próprio é igual a 1 e, logo, localiza-se no eixo *x*. Graficamente, quanto mais próximo o ponto de um método à referência, melhor o método de interpolação. O diagrama de Taylor fornece uma maneira conveniente, gráfica, de comparar os dados observados e estimados.

Figura 6 – Exemplo de construção do diagrama de Taylor.



Fonte: Adaptado de Pereira et al., (2014).

3.6.5 Mapas de anomalias (desvios)

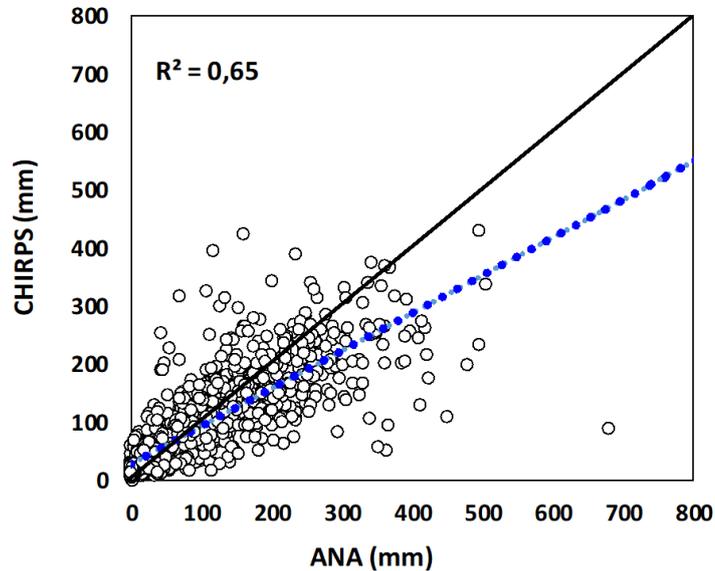
Para a previsão climática é importante avaliar quanto um valor previsto se afasta do observado no período de referência, ou seja, a climatologia referente ao período de *hindcasts* do MFS7. Assim, apesar de termos dados CHIRPS sobre a BHM a partir de 1981, que motivaram o detalhamento da climatologia 1981-2020 da precipitação mensal, sazonal e anual mostrada nos resultados, para fins de comparação e obtenção dos desvios previstos em relação à observação, a referência climatológica foi de 1993-2016 a fim de ter a mesma extensão temporal do período de *hindcast*, sendo usado esse período em todas as etapas de avaliação da destreza das previsões recalibradas quanto na avaliação do estudo de caso para as previsões realizadas para o ano de 2020.

4. RESULTADOS

4.1 Dados de chuva estimados pelo CHIRPS

A Figura 7 apresenta os dados observados e as estimativas do CHIRPS. O coeficiente de determinação foi de 0,65, o que significa que em torno de 65% da variabilidade observada foi bem captada pelas estimativas do CHIRPS. O coeficiente de correlação foi de 0,81, com um viés (bias) baixo, de apenas 3,5 mm, um erro médio absoluto de 4,3 mm e um erro quadrático médio de 18,9 mm. Estes números corroboram que o CHIRPS é uma fonte de dados confiável para a estimativa das chuvas acumuladas na BHM.

Figura 7 – Diagrama de dispersão entre valores mensais observados em estações da ANA na BHM, e estimados pelo CHIRPS para as coordenadas geográficas dessas estações em dias com ocorrência de precipitação.



Fonte: autor.

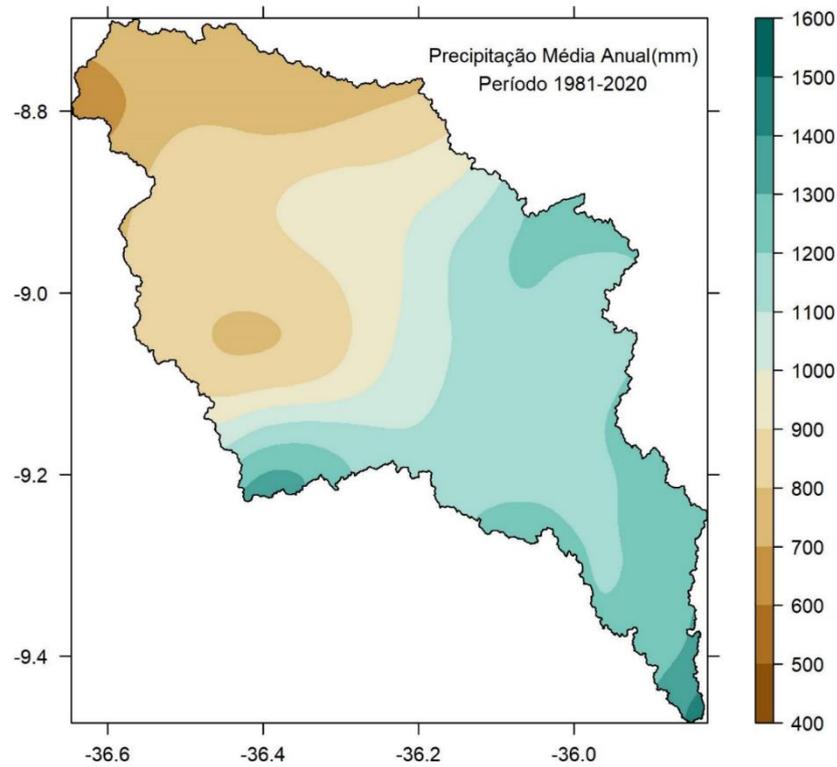
O CHIRPS tem boa capacidade de espacialização dos dados quando comparados aos dos postos pluviométricos, além de apresentar maior série de dados pluviométrico do que um posto convencional. O CHIRPS é um ótimo produto de espacialização dos dados pluviométricos na ausência de um número significativo de postos pluviométricos (RABELO; SANTOS; FILHO, 2022).

Parte da BHM está inserida na nova fronteira agrícola do Brasil, a SEALBA, em estudo sobre performance de diferentes fontes de dados para essa região entre os estados de Alagoas, Sergipe e Bahia, Silva et al., (2022) mostraram que o CHIRPS foi a segunda fonte de dados que apresentava mais similaridade com as observações nessa área do leste brasileiro, perdendo apenas para a fonte de dados gradeada conhecida pela sigla MERGE, do INPE, o que corrobora a escolha do CHIRPS como uma boa fonte de dados para o desenvolvimento dessa pesquisa e avaliação da performance das previsões do MFS7 na BHM.

4.2 Climatologia da BHM

Ao analisar a distribuição espacial da precipitação (Figura 8), percebe-se que os maiores valores se encontraram próxima a região litorânea do Atlântico no sudeste da bacia. Ainda, à medida que se afasta da região litorânea, ocorre a redução das chuvas em municípios que estão na região semiárida. O mesmo foi observado por (SILVA et al., 2018) que estudou a variabilidade espaço temporal da precipitação na BHM para o período de 1986 a 2016.

Figura 8 – Climatologia anual, 1981 a 2020.



Fonte: autor.

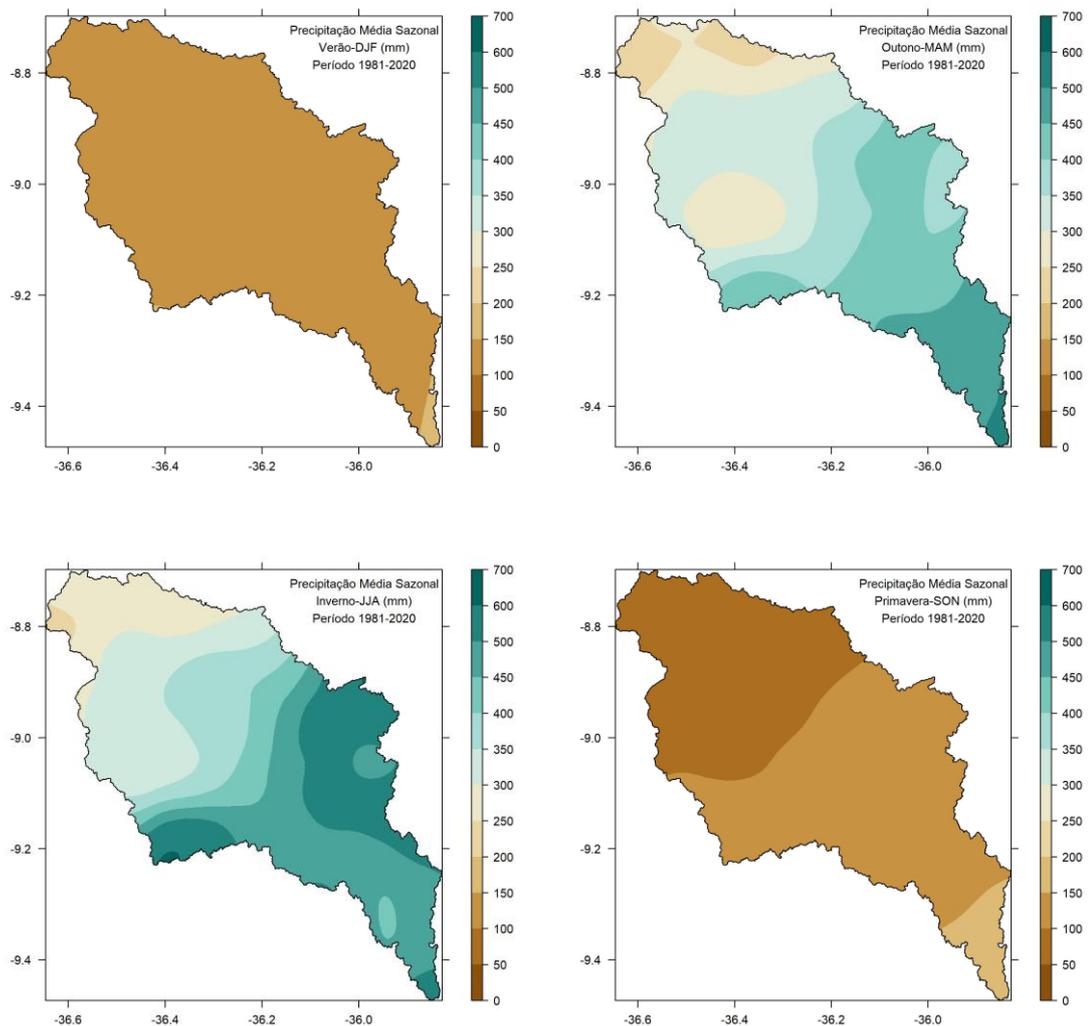
A BHM é marcada por forte sazonalidade (Figura 9), com chuvas concentradas no outono/inverno mais concentradas na porção sudeste da bacia, com acumulados médios que podem superar os 700mm. A primavera é a estação mais seca, um resultado interessante por ser a estação que sucede à mais chuvosa, de inverno, mais seca inclusive do que o verão, onde a atuação de alguns sistemas específicos pode levar alguma precipitação à BHM. Esses resultados são coerentes com os principais sistemas de precipitação atuantes no leste do Nordeste brasileiro, tais como: zona de convergência inter-tropical, frentes de nuvens, vórtice troposférico dos altos níveis, brisa marítima e outros (FERREIRA; MELLO, 2005).

O fenômeno mais expressivo para esse setor da BHM é denominado de Distúrbio Ondulatório de Leste (DOL), também conhecido por Perturbações Ondulatórias dos Alísios e Ondas Africanas, são caracterizadas como pacotes de instabilidade que se propagam pelo fluxo dos ventos Alísios partindo da costa oeste da África até o NEB durante o inverno do hemisfério sul (FERREIRA; MELLO, 2005). Segundo Coutinho & Fisch (2007) os DOLs ocorrem durante todo o ano sobre o leste do NEB, porém sua ocorrência é intensificada nos meses de maio a agosto, marcando o período chuvoso do litoral leste do NEB.

Associado a outros fenômenos tropicais, o chamado Vórtice Ciclônico de Altos Níveis (VCAN), é outro fenômeno responsável por parte da precipitação anual em alguns setores do

NEB (PINHEIRO, 2015). A chuva ocasionada pelo fenômeno depende da sua posição sobre a região. Como documentado por Morais (2016) e De Souza Ferreira (2020), seu centro é caracterizado por estabilidade, enquanto os lugares do NEB localizados sobre a periferia do fenômeno sob recebem toda a chuva da área instável do fenômeno. VCANs pode atuar por até 8 dias e é o principal fenômeno de grande escala que provoca chuva na região central do NEB, e no caso da BHM, influência de forma dúbia a depender de seu posicionamento, podendo inibir fortemente as chuvas quando tem seu centro sobre a bacia, ou levando eventos de chuvas a bacia durante o verão.

Figura 9 – Climatologia sazonal.

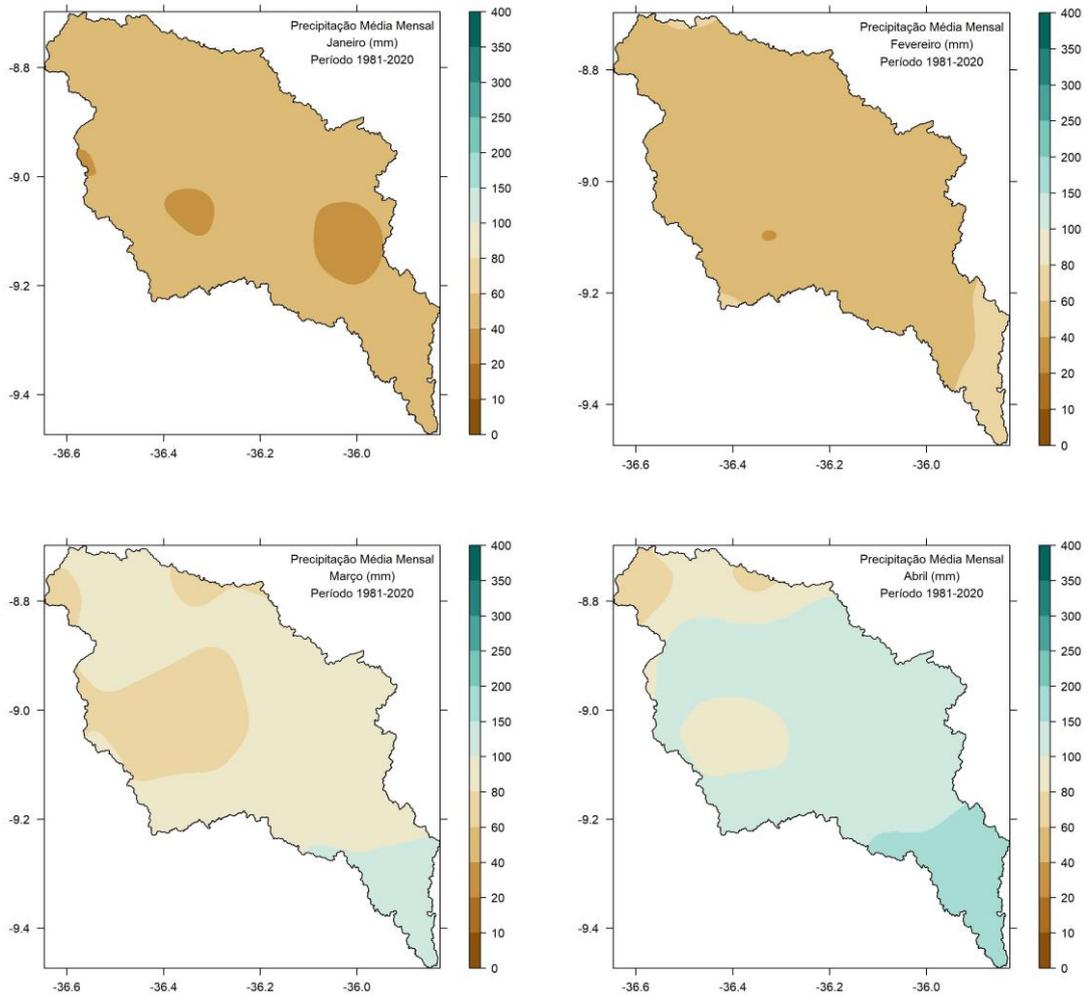


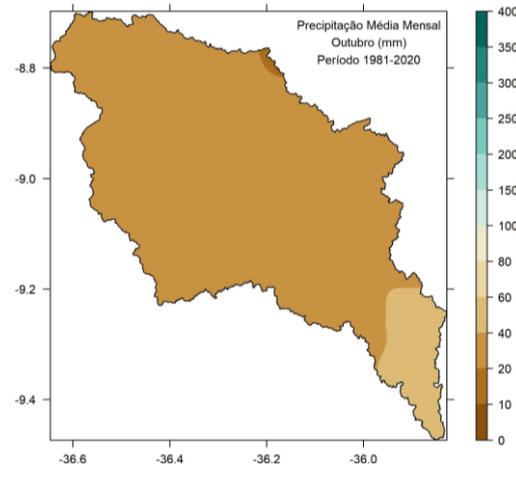
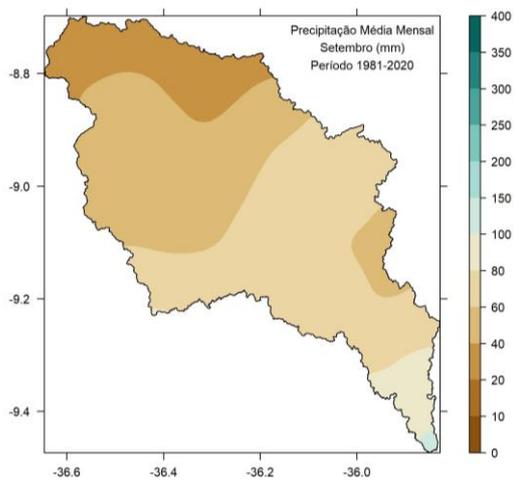
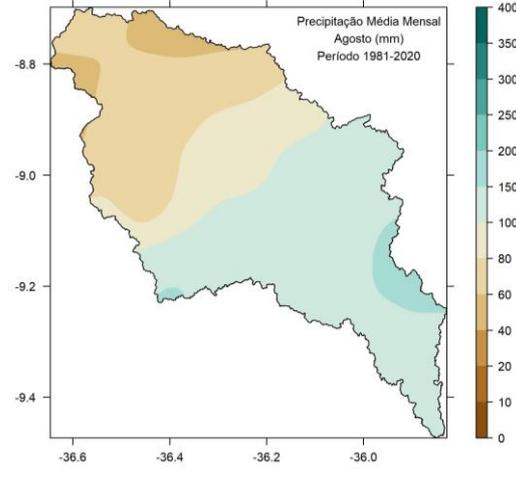
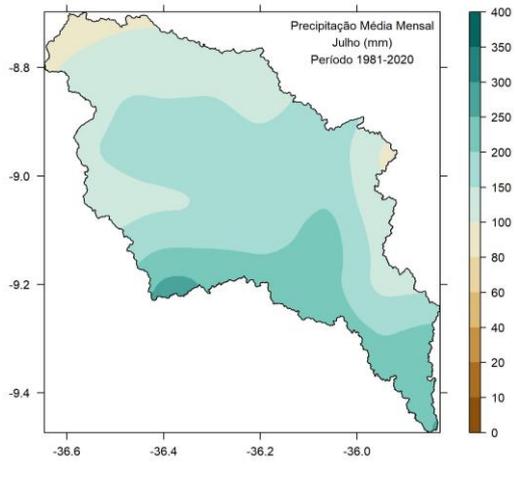
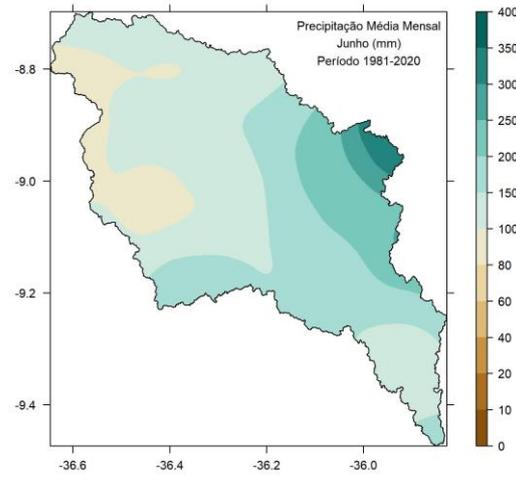
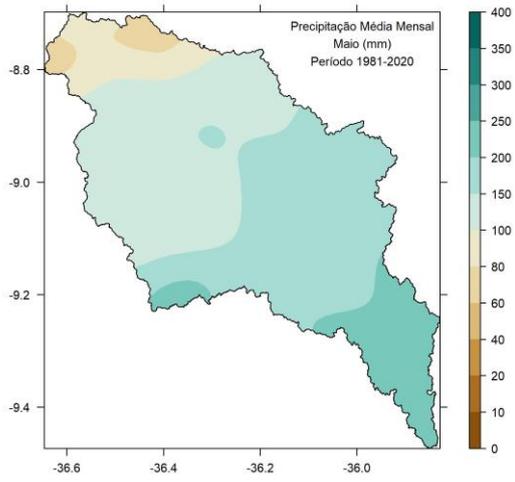
Fonte: autor.

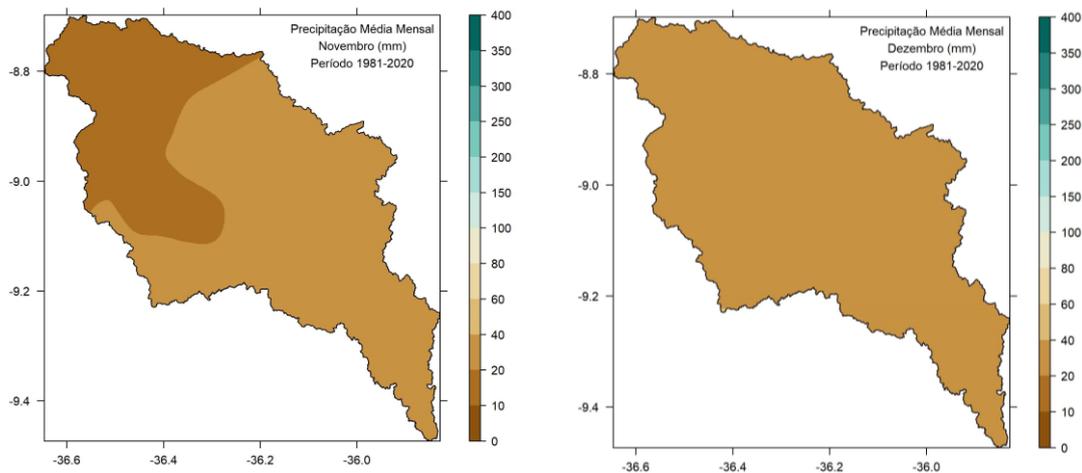
Acerca da climatologia mensal (Figura 10), em abril observa-se o aumento da precipitação, prevalecendo em maio, atingindo seus máximos em junho que é o mês com os maiores picos na BHM, assim como aquele onde há mais probabilidade de ocorrência de

desastres causados por cheias. Junho atinge a sua máxima precipitação na zona da mata e sudeste alagoano, onde ocorrem valores acima do chovido no litoral alagoano. O mês de julho é o segundo mais chuvoso da BHM, contribuindo significativamente para o total anual da bacia. Em agosto se torna perceptível a redução brusca principalmente na região noroeste.

Figura 10 – Climatologia mensal.







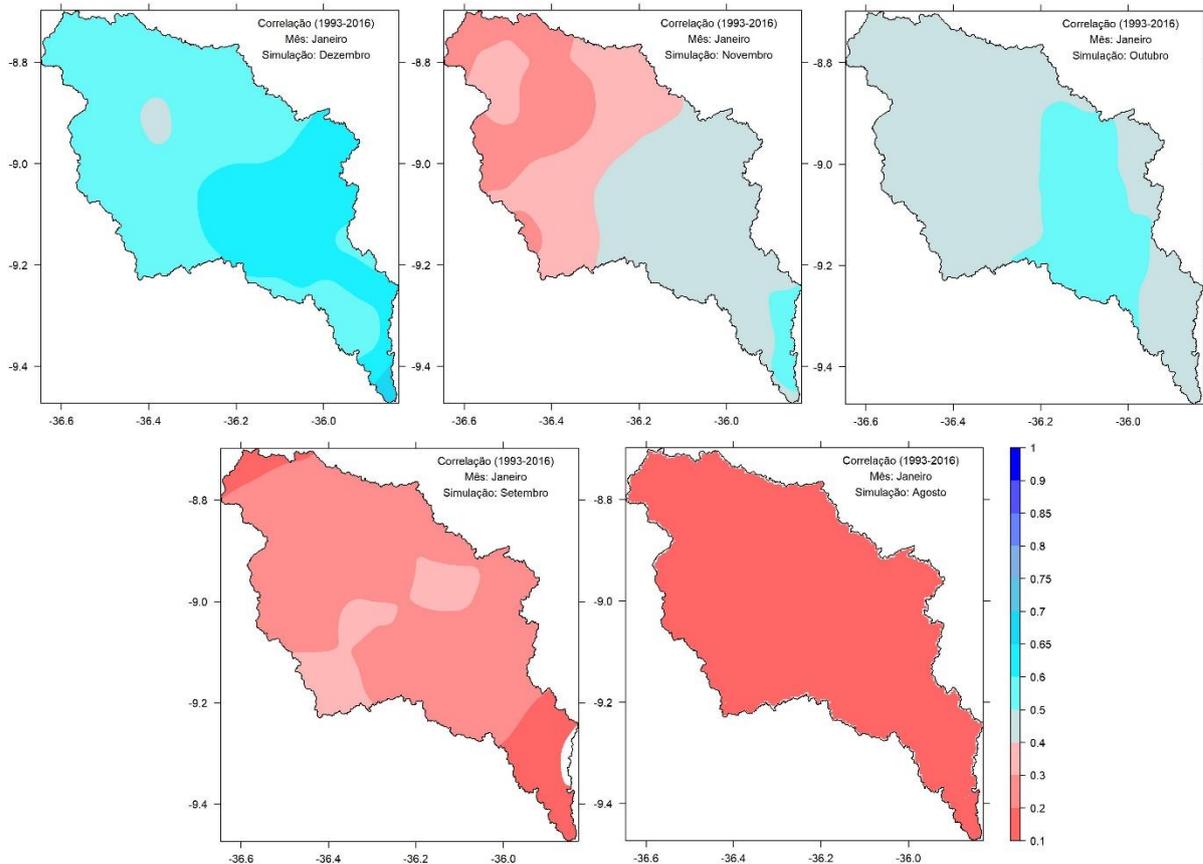
Fonte: autor.

4.3 Previsão climática do MFS7 via ACC – análise das correlações mensais

Poder se antecipar em até 5 meses em relação ao prognóstico climático das chuvas acumuladas é um dos maiores objetivos dos centros globais de produção de previsões climáticas mundiais coordenados pela OMM. No entanto, como é conhecido, isso já é possível em nível global por diferentes modelos, mas ainda sendo necessário que ajustes sejam realizados a fim de que se possa extrair o que há de melhor do potencial preditivo de cada modelo.

Os mapas das Figura 11 e Figura 22 mostram a análise das correlações obtidas entre a precipitação simulada com até cinco meses de antecedência com o MFS7 após utilização da técnica de ACC, para cada mês do ano. Para o mês de janeiro, a Figura 18 mostra a correlação das previsões obtidas em dezembro, novembro, outubro, setembro e agosto, respectivamente. As previsões melhor correlacionadas com as observações são as obtidas com um mês de antecedência, com predomínio da área em tons de cor azul. Devido a extensão do *hindcast*: 1993-2015, correlações maiores que 0,4 são estatisticamente significantes a um nível de confiança de 95% pelo teste *t-student*, e valores abaixo não possuem significância estatística. Logo, os tons de azul nos dão um indicativo das áreas com maior confiabilidade das previsões. As previsões para janeiro realizadas em outubro também possuem significância em boa parte da BHM, destacando-se sua porção centro-sul. Previsões realizadas em novembro possuem baixa confiança, apenas no extremo sudeste da bacia, e as realizadas em setembro e agosto não possuem qualquer confiabilidade.

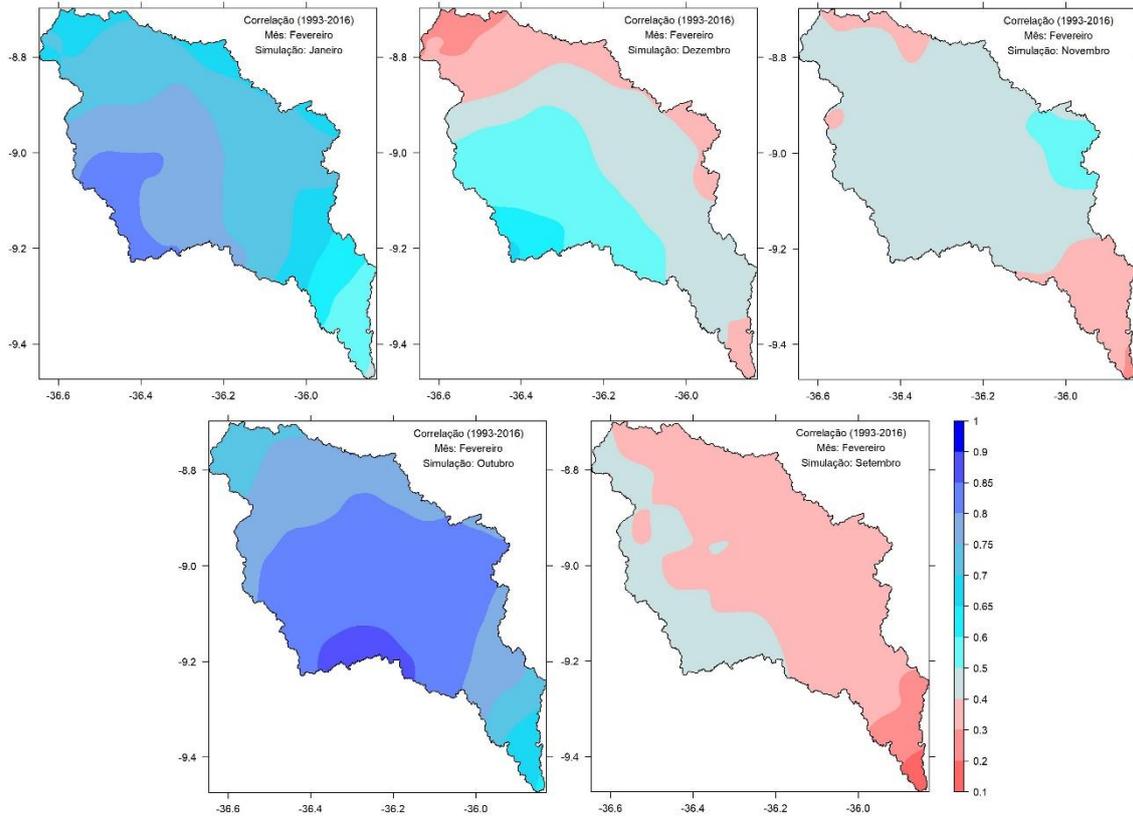
Figura 11 – Correlações entre observações e previsões geradas para o mês de janeiro variando de um a cinco meses de antecedência (dezembro a agosto do ano anterior).



Fonte: autor.

Para o mês de fevereiro, a Figura 12 mostra altas correlações, indicativo de alta confiabilidade das previsões, para aquelas realizadas com um e quatro meses de antecedência, respectivamente nos meses de janeiro do ano corrente e outubro do ano anterior. As previsões realizadas em dezembro, novembro e setembro possuem poucas áreas com correlações superiores a 0,4, logo as previsões realizadas nesses meses para fevereiro do ano seguinte possuem baixos índices de acertos. O destaque para esse mês é que as previsões de outubro de um ano para o fevereiro seguinte possuem as maiores correlações, chegando a ultrapassar 0,8 em parte do centro-sul da BHM, ou seja, com quatro meses de antecedência é possível prever com boa destreza se os acumulados de precipitação de fevereiro tenderão a se afastar ou não da média climatológica, assumindo algum desvio positivo ou negativo, ou mesmo se os acumulados tenderão a valores normais.

Figura 12 – Idêntica a figura 18, mas para fevereiro.

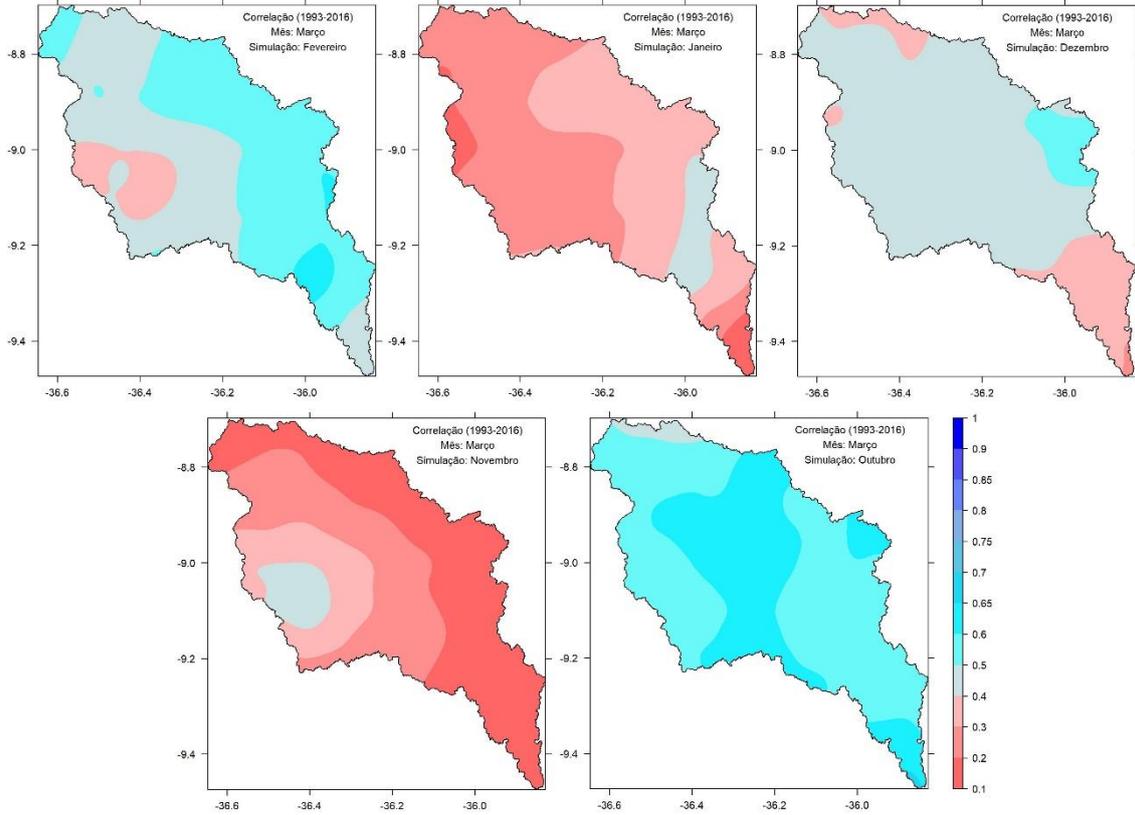


Fonte: autor.

Para as previsões de março, a Figura 13 traz um resultado interessante: as maiores correlações são observadas para a previsão realizada com maior tempo de antecedência, em outubro do ano anterior, com correlações superiores a 0,5 em toda a área da BHM. Previsões geradas para março nos meses de janeiro e novembro não possuem significância estatística, enquanto a confiabilidade das previsões realizadas em fevereiro e dezembro é restrita a pequenas áreas ao leste da BHM.

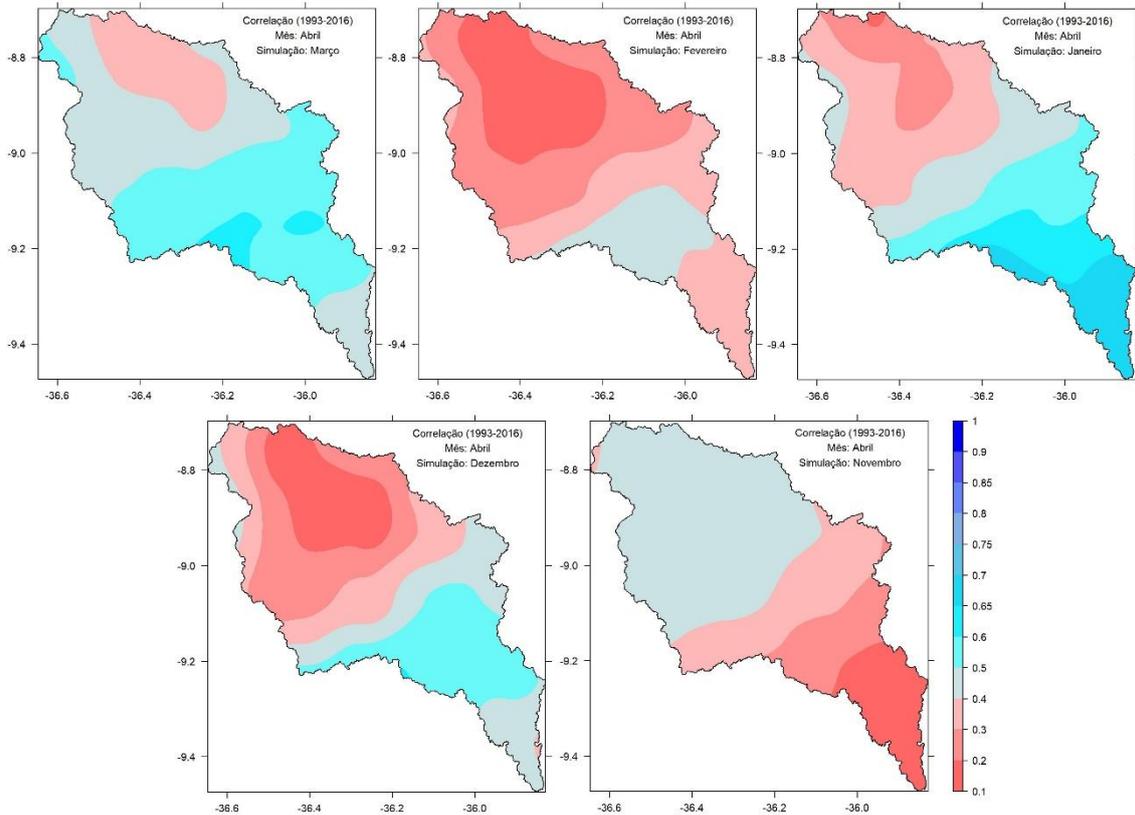
Para abril (Figura 14), a maior parte das previsões tem correlações muito baixas principalmente no centro-norte da BHM. As partes central e sul da BHM possuem correlações mais altas e significantes para as previsões realizadas nos meses de março e janeiro, esta última com correlações próximas a 0,7. As previsões realizadas em fevereiro a novembro possuem pouca ou nenhuma confiabilidade, e as realizadas em dezembro tem correlações que variam de 0,5 a 0,6 também no centro-sul da BHM.

Figura 13 – Idêntica a figura 18, mas para março.



Fonte: autor.

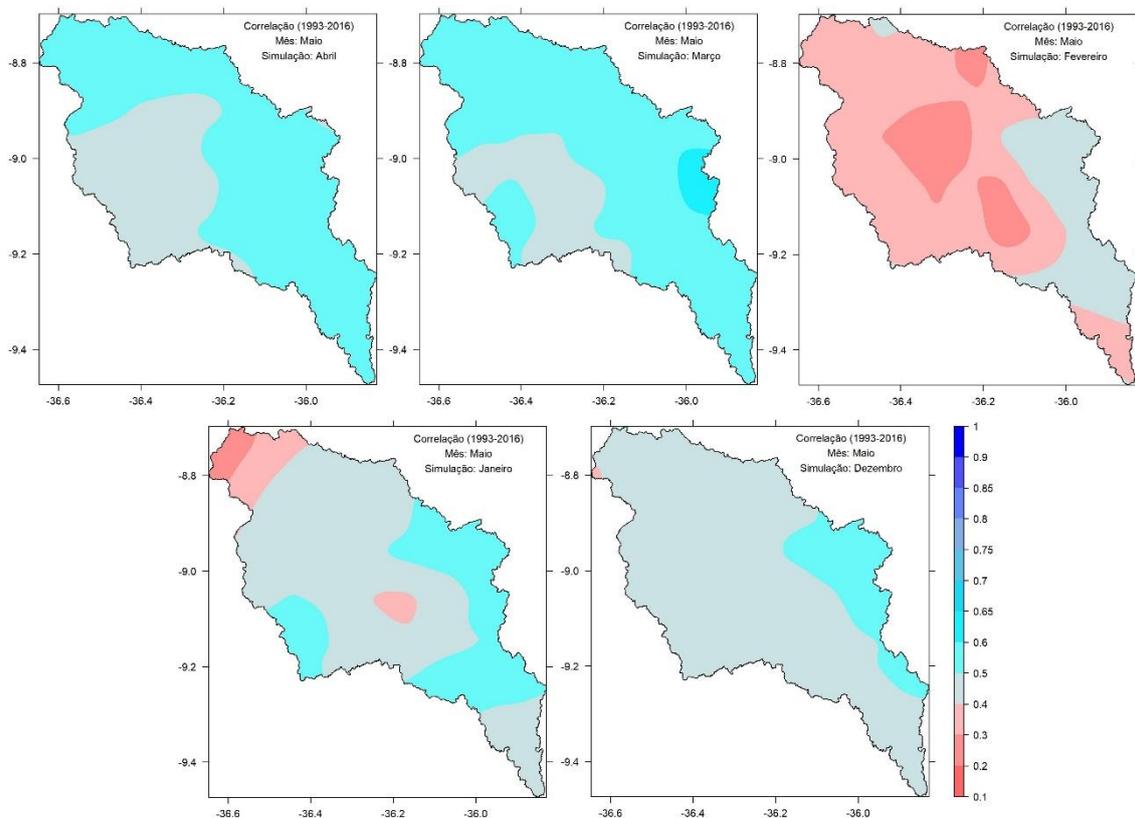
Figura 14 – Idêntica a figura 18, mas para abril.



Fonte: autor.

As previsões geradas para maio (Figura 15), com exceção da realizada em fevereiro, possuem valores de correlação muito próximos, de 0,4 a 0,65, com os maiores valores no setor leste da BHM. Vale ressaltar que a partir de maio observa-se o aumento climatológico do acumulado de precipitação, logo, previsões realizadas para o período úmido da BHM, de preferência, deveriam ser aquelas com maior potencial de confiança. Este fator de confiabilidade é verificado para as previsões dos meses de junho a agosto, que juntamente com maio, formam a quadra mais chuvosa do ano na BHM.

Figura 15 – Idêntica a figura 18, mas para maio.

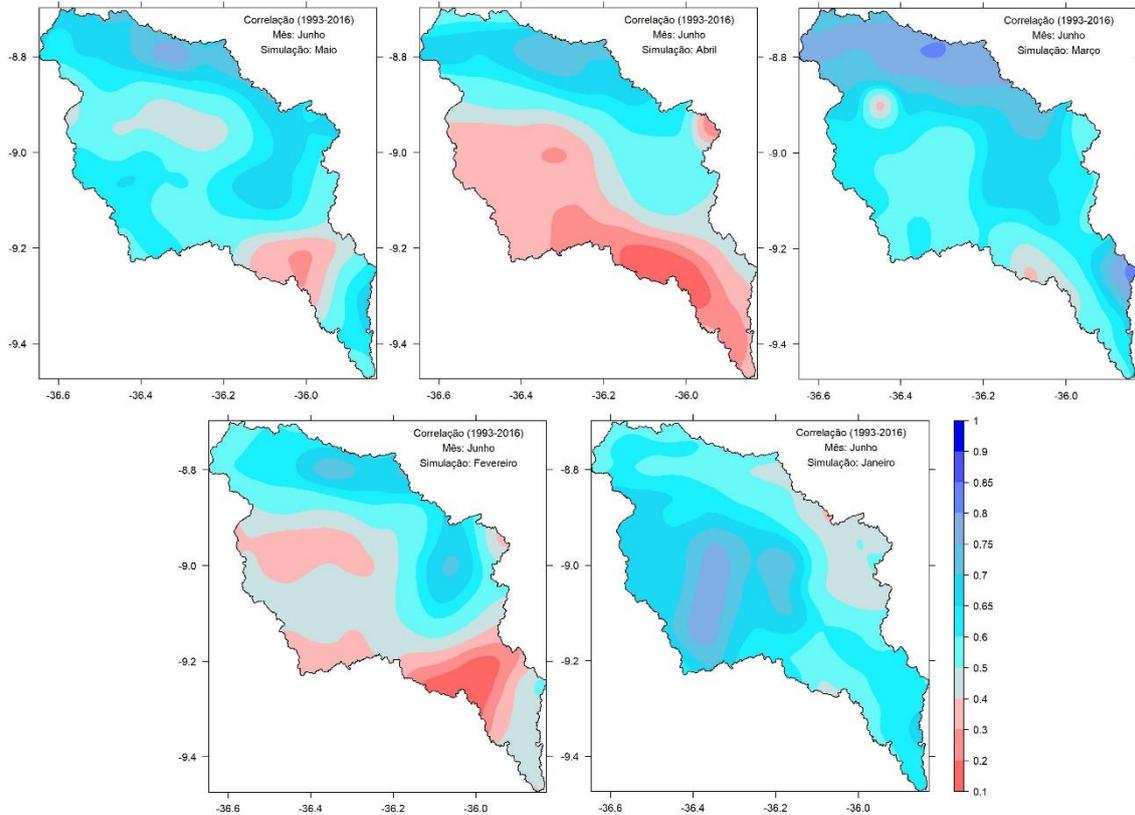


Fonte: autor.

Para junho (Figura 16), observa-se altas correlações entre previsões e observações, com destaque para os setores norte e nordeste da BHM para as previsões realizadas em maio, abril, março e fevereiro, ultrapassando o valor de 0,8 na previsão de março. O centro-oeste da BHM tem as melhores correlações na previsão realizada em janeiro, ou seja, cinco meses atrás. Há áreas com correlações muito baixas no centro-leste da bacia para a previsão de junho realizada em abril e fevereiro, no entanto, percebe-se que deve-se ficar atento a todas as previsões de junho desde janeiro no caso de um sistema operacional que por ventura essa metodologia para

antever possibilidades de acumulações acima e abaixo da média em um mês que é o mais chuvoso da BHM.

Figura 16 – Idêntica a figura 18, mas para junho.



Fonte: autor.

Para julho (Figura 17), mês chuvoso na BHM, as previsões mais acuradas são aquelas realizadas com um e dois meses de antecedência, em junho e maio. Para agosto (Figura 18), as características das correlações das previsões são similares às observadas para o mês de junho, com valores moderados a fortes de correlação vistos em cada mês de realização das previsões, com destaque para o sul da BHM na previsão de junho, e norte da BHM nas previsões de julho, junho, maio e abril. O centro da BHM possui as áreas com menores correlações em praticamente todas as previsões realizadas para agosto, com exceção da realizada em abril.

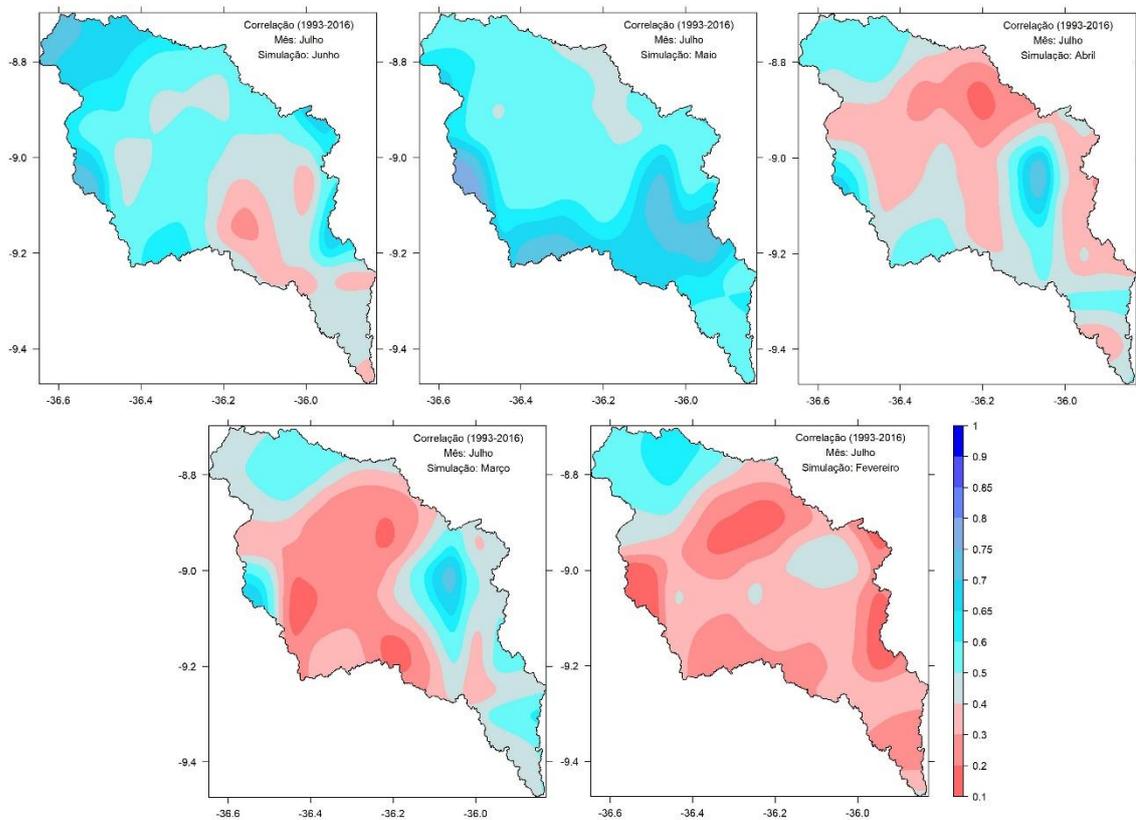
As previsões realizadas para setembro (Figura 19) têm destaques para a mais recente feita em agosto e a mais distante feita em abril, com correlações moderadas a altas em toda a BHM, já nas realizadas em julho, junho e maio predominam correlações baixas sem significância estatística. A Figura 20 mostra as correlações para as previsões realizadas para o mês de outubro, cujo destaque são as baixas correlações observadas em todas as previsões.

Para novembro (Figura 21), as previsões com três e quatro meses de antecedência são as que tem as maiores correlações, principalmente no sul da BHM onde estas chegam a 0.8. Já

as previsões mais recentes para esse mês realizadas em outubro e setembro tem correlações muito baixas e a mais distante, realizada em junho tem todas as correlações entre 0,1 e 0,2, muito baixas.

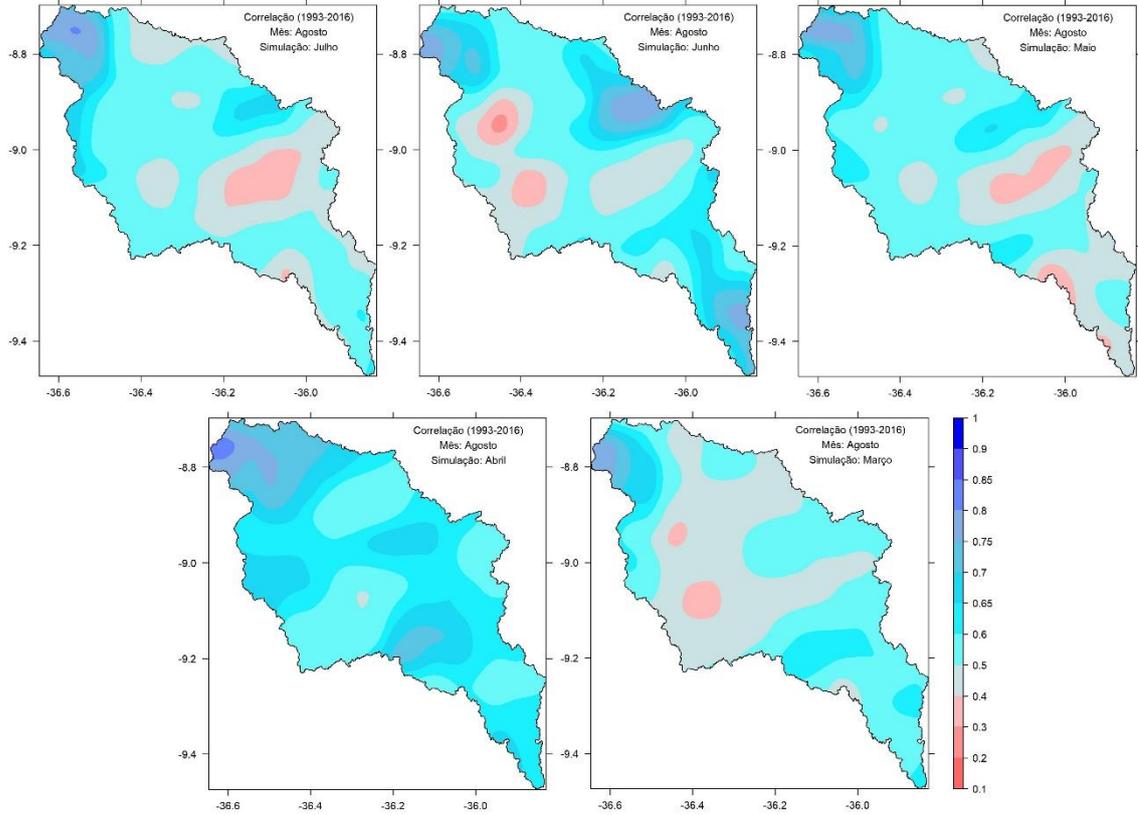
Já para dezembro (Figura 22), percebe-se características similares as previsões para outubro, com correlações baixas em quase todos os meses anteriores onde geram-se previsões para dezembro, com pequenas áreas com correlações que chegam a atingir o valor de 0,5 no norte da BHM nas previsões geradas com dois e três meses de antecedência, em outubro e setembro.

Figura 17 – Idêntica a figura 18, mas para julho.



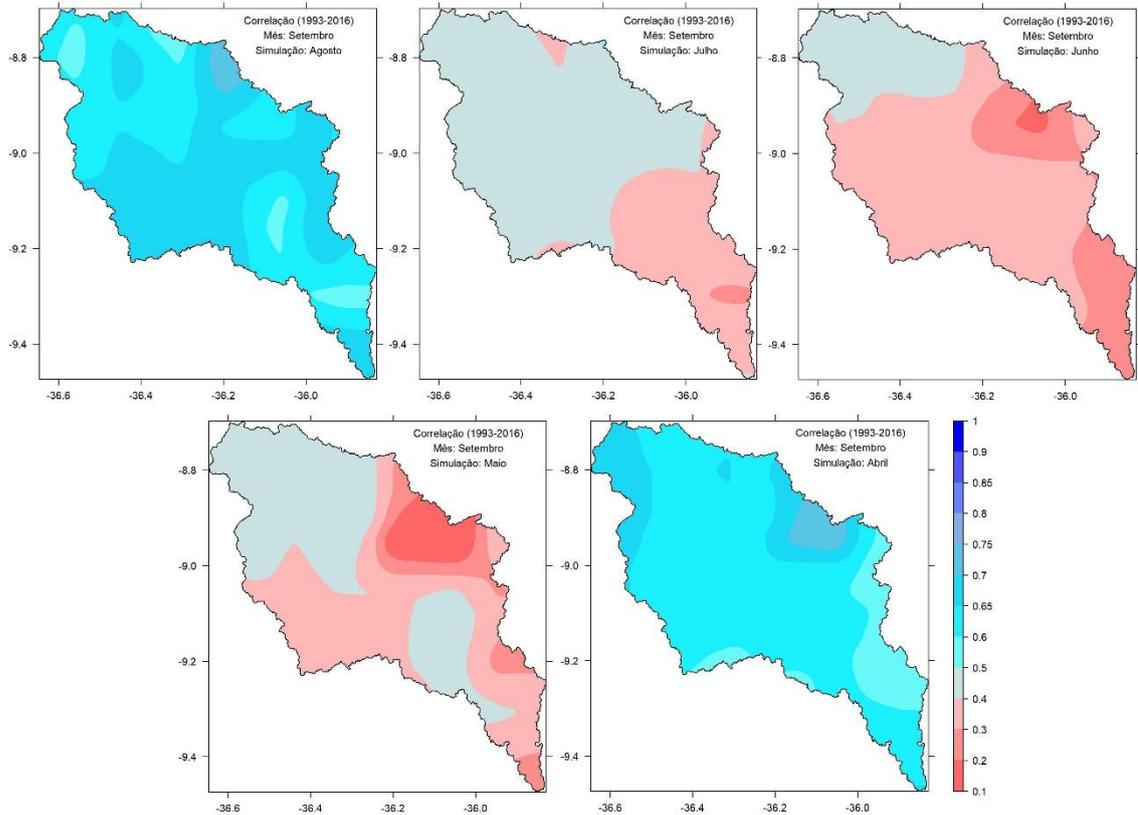
Fonte: autor.

Figura 18 – Idêntica a figura 18, mas para agosto.



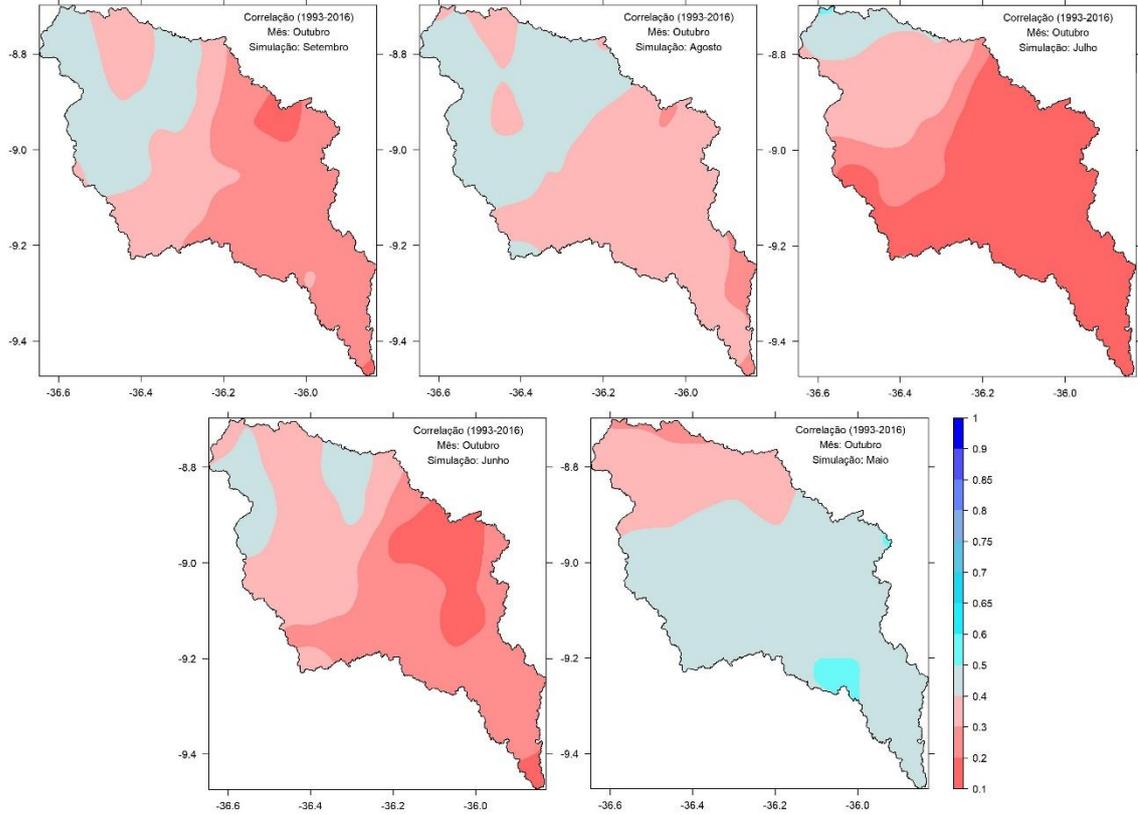
Fonte: autor.

Figura 19 – Idêntica a figura 18, mas para setembro.



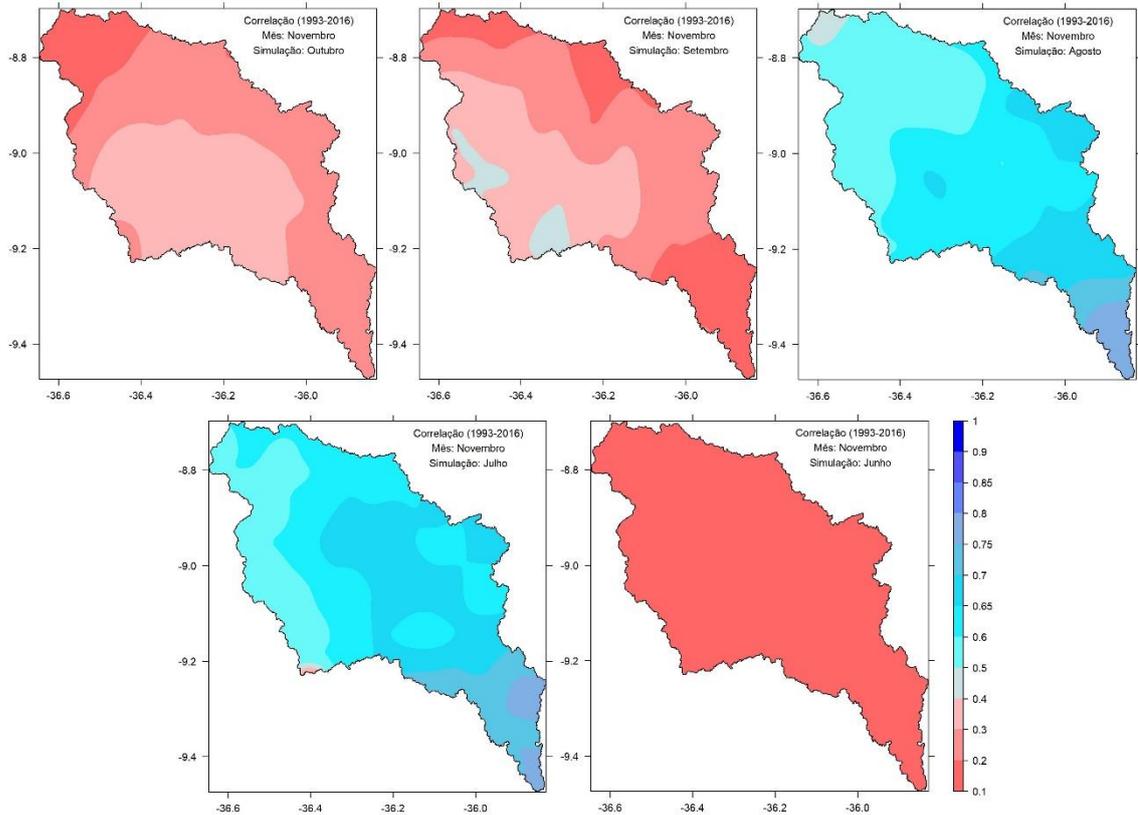
Fonte: autor.

Figura 20 – Idêntica a figura 18, mas para outubro.



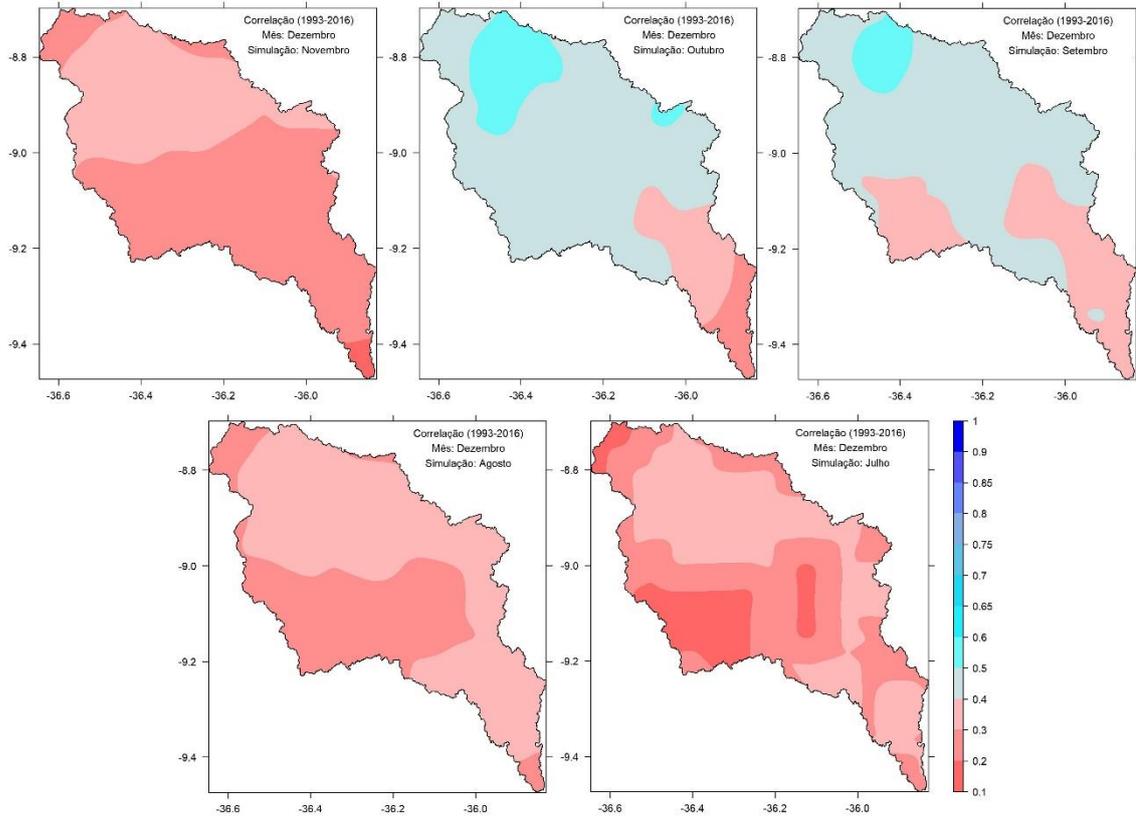
Fonte: autor.

Figura 21 – Idêntica a figura 18, mas para novembro.



Fonte: autor.

Figura 22 – Idêntica a figura 18, mas para dezembro.



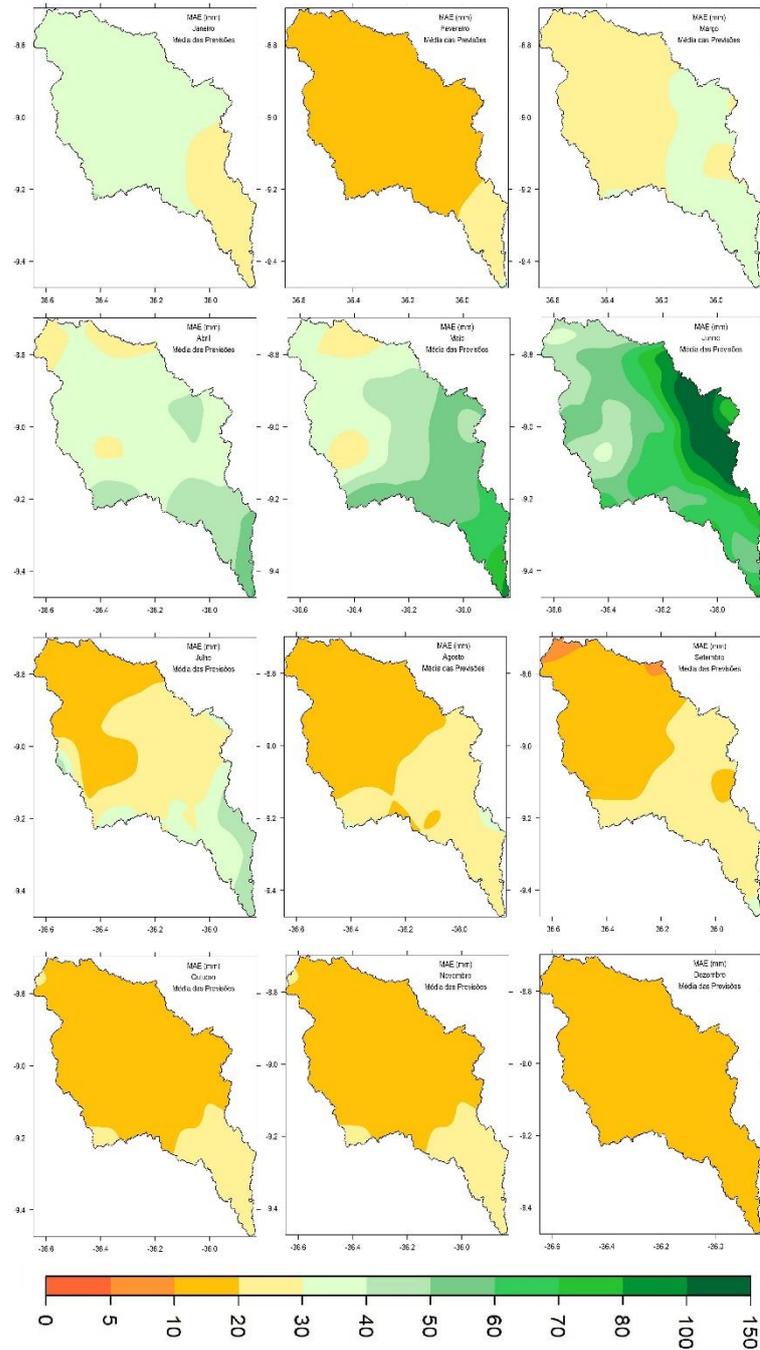
Fonte: autor.

4.4 Previsão climática do MFS7 via ACC – análise dos erros

As Figura 23 e Figura 24 mostram o MAE e RMSE, respectivamente, associados à média das cinco previsões recalibradas obtidas para cada mês. Essa é uma estratégia para enxugar os resultados em uma única imagem para cada mês. Os erros associados são proporcionais aos acumulados mensais, ou seja, para meses com baixos valores de precipitação, menores erros, para aqueles com maiores acumulações maiores erros. No entanto, apesar de esperado esse resultado mostra-se bastante relevante e erros maiores em meses mais chuvosos não são um indicativo direto de baixa performance das previsões do modelo.

Para o MAE é perceptível maiores erros no trimestre abril a junho, a partir de 30 a 70 mm/mês em abril, de 30 a 100 mm/mês em maio e de 40 a pouco mais de 150 mm/mês em junho, com os demais meses com erros absolutos de 0 a 40 mm/mês. Pelo MAE, de abril a junho espera-se os maiores desvios do modelo em relação as observações, o que pode ser ou um sinal positivo ou negativo, positivo no sentido do modelo conseguir captar um sinal acima ou abaixo e acabar estimando um valor superior a anomalia observada, e negativo se essa anomalia captada pelo modelo for de sentido oposto ao da observação.

Figura 23 – MAE da média das previsões de cada mês do ano.

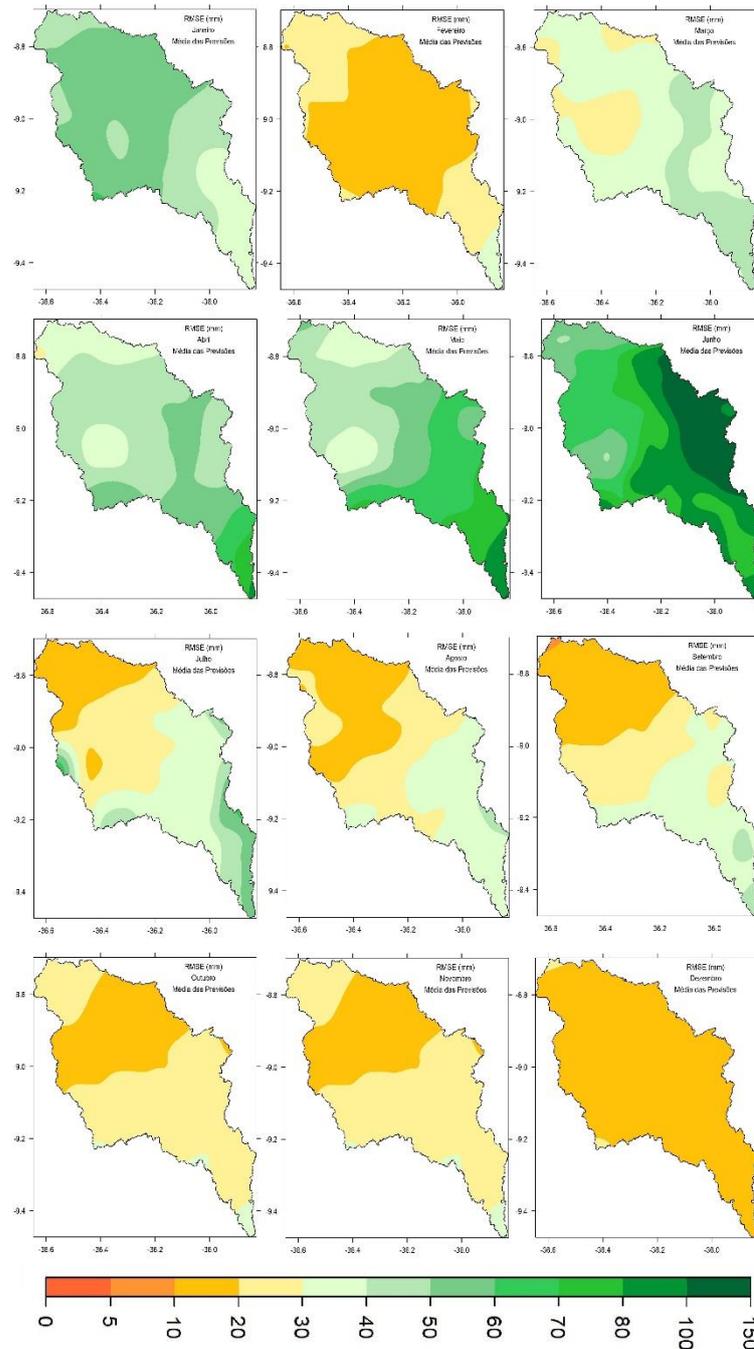


Fonte: autor.

O RMSE pode parecer um índice redundante ao MAE, mas potencializa os erros do modelo permitindo identificar meses em que os erros podem ser consideráveis e que não são captados pelo MAE, já que este contabiliza desvios positivos e negativos em um valor absoluto. O RMSE ao elevar os quadrados das diferenças, permite identificarmos que meses como janeiro tem comportamento dos erros similar aos de abril, não identificado pelo MAE. Assim como percebe-se erros de magnitude moderada de previsões realizadas para março, julho, agosto e

setembro no centro-sul da BHM. A magnitude dos erros indica que muitas vezes o MFS7 após recalibração com ACC prevê valores que se distanciam das observações, o que pode ser encarado de forma positiva pois pode-se inferir que o modelo tem capacidade de simular valores extremos que se afastam da média climatológica, pois modelos cujas previsões pouco se afastam da climatologia não tem valor para um sistema de previsão climática operacional.

Figura 24 – RMSE da média das previsões de cada mês do ano.



Fonte: autor.

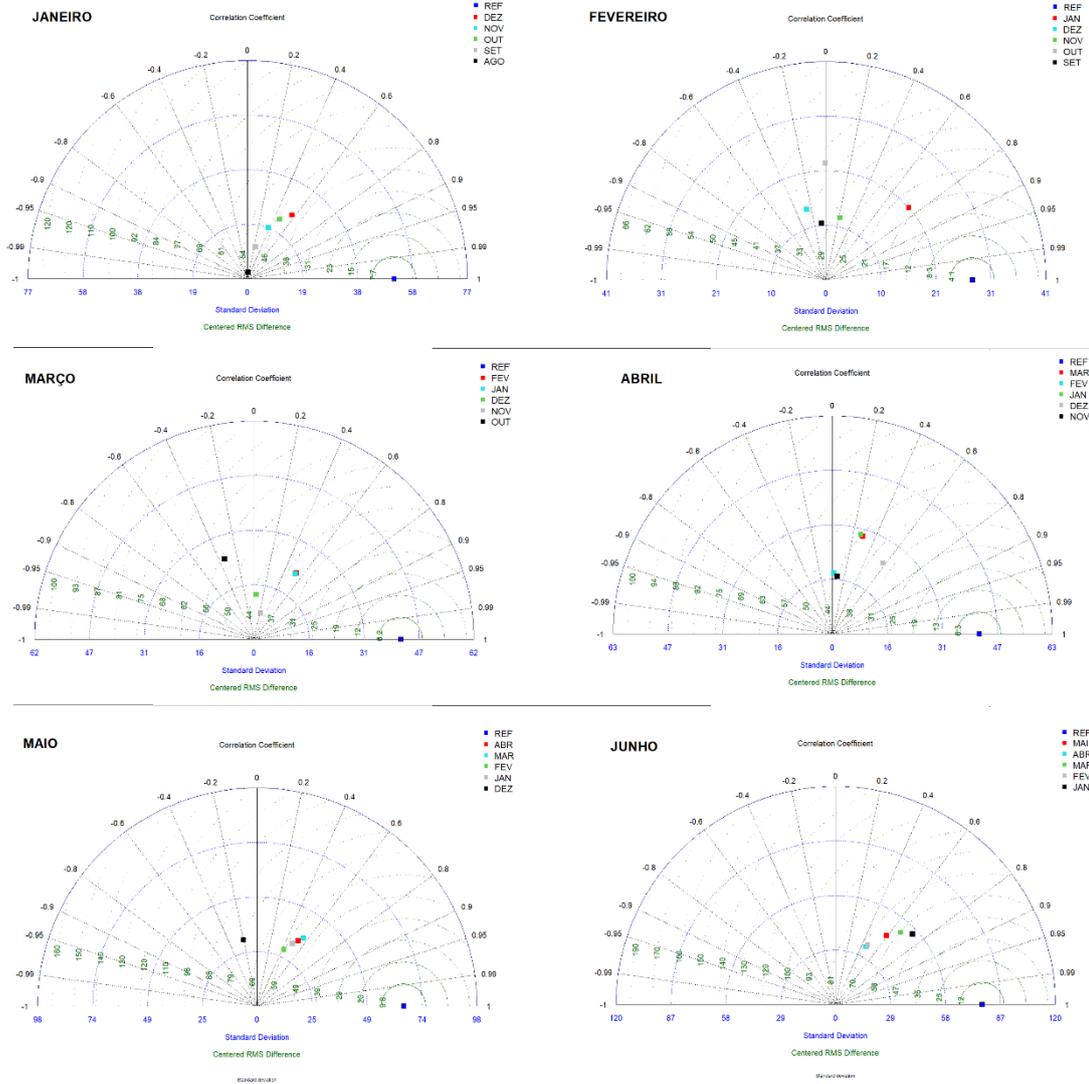
4.5 Análise de diagramas de Taylor

Os diagramas de Taylor permitem sintetizar de forma eficiente as informações provenientes de três parâmetros: correlação, desvio-padrão e erro quadrático médio. Viu-se das figuras das correlações que para alguns meses quase todas as previsões iniciadas meses antes tem o mesmo padrão de correlações, enquanto para outros meses não. Viu-se também que é preciso mais de uma medida dos erros das previsões para inferir sobre os meses que estes podem ser maiores em relação as observações. Em um centro operacional o previsor precisa saber em qual previsão gerada meses atrás para o mês atual tem maior potencial de acerto baseado nos melhores indicadores (maior correlação e menor erro).

A análise do diagrama de Taylor permite isso, com flexibilidade para identificar qual o mês mais assertivo para a previsão climática (GU et al., 2018), aumentando a qualidade da discussão sobre o desempenho e a escolha do melhor resultado do modelo (GOMES et al., 2022). A Figura 25 mostra os diagramas de Taylor de janeiro a junho, onde nota-se que, para os dados observados (referencia) tem-se que as melhores previsões em ordem decrescente realizadas para cada mês, são as de dezembro, outubro, novembro, setembro e agosto para janeiro, respectivamente; janeiro, novembro, outubro, setembro e dezembro para fevereiro, respectivamente; fevereiro, janeiro, dezembro, novembro e outubro para março, respectivamente; dezembro, março, janeiro, novembro e fevereiro para abril, respectivamente; março, abril, janeiro, fevereiro e dezembro para maio, respectivamente; e janeiro, março, maio, fevereiro e abril para junho, respectivamente.

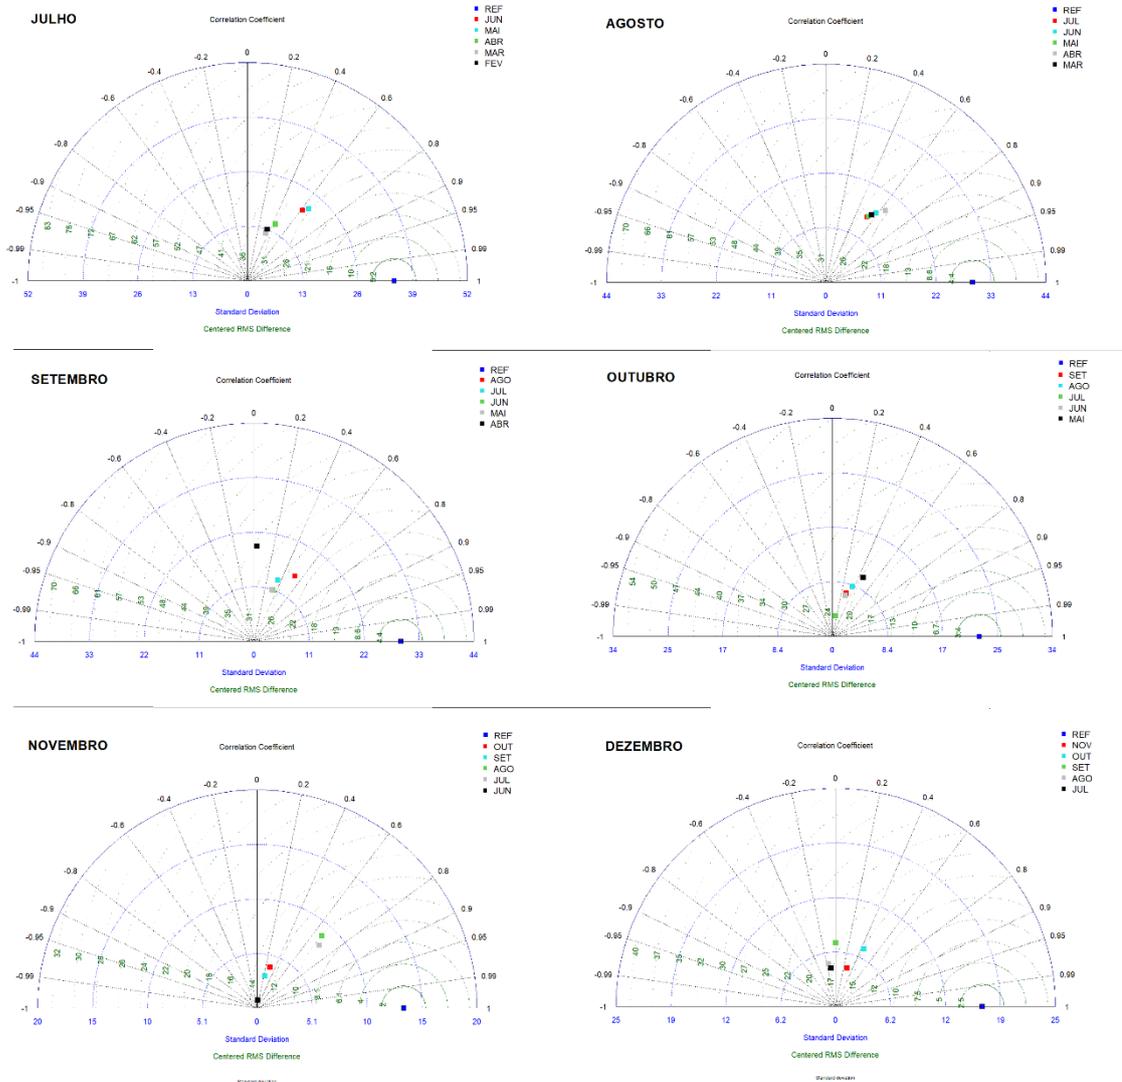
A Figura 26 mostra os diagramas de Taylor de julho a dezembro, onde nota-se que, para os dados observados (referencia) tem-se que as melhores previsões em ordem decrescente realizada para cada mês são as de maio, junho, abril, fevereiro e março para julho, respectivamente; abril, junho, março, maio e julho para agosto, respectivamente; agosto, julho, junho, maio e abril para setembro, respectivamente; maio, agosto, setembro, junho e julho para outubro, respectivamente; agosto, julho, outubro, setembro e junho para novembro, respectivamente; e outubro, novembro, setembro, julho e agosto para dezembro, respectivamente.

Figura 25 – Aplicação do diagrama de Taylor representando graficamente as estatísticas relativas as observações e previsões obtidas até cinco meses antes do mês atual, para janeiro, fevereiro, março, abril, maio e junho.



Fonte: autor.

Figura 26 – Aplicação do diagrama de Taylor representando graficamente as estatísticas relativas as observações e previsões obtidas até cinco meses antes do mês atual, para julho, agosto, setembro, outubro, novembro e dezembro.



Fonte: autor.

4.6 Previsão climática por conjunto do MFS7 via ACC – análise das correlações

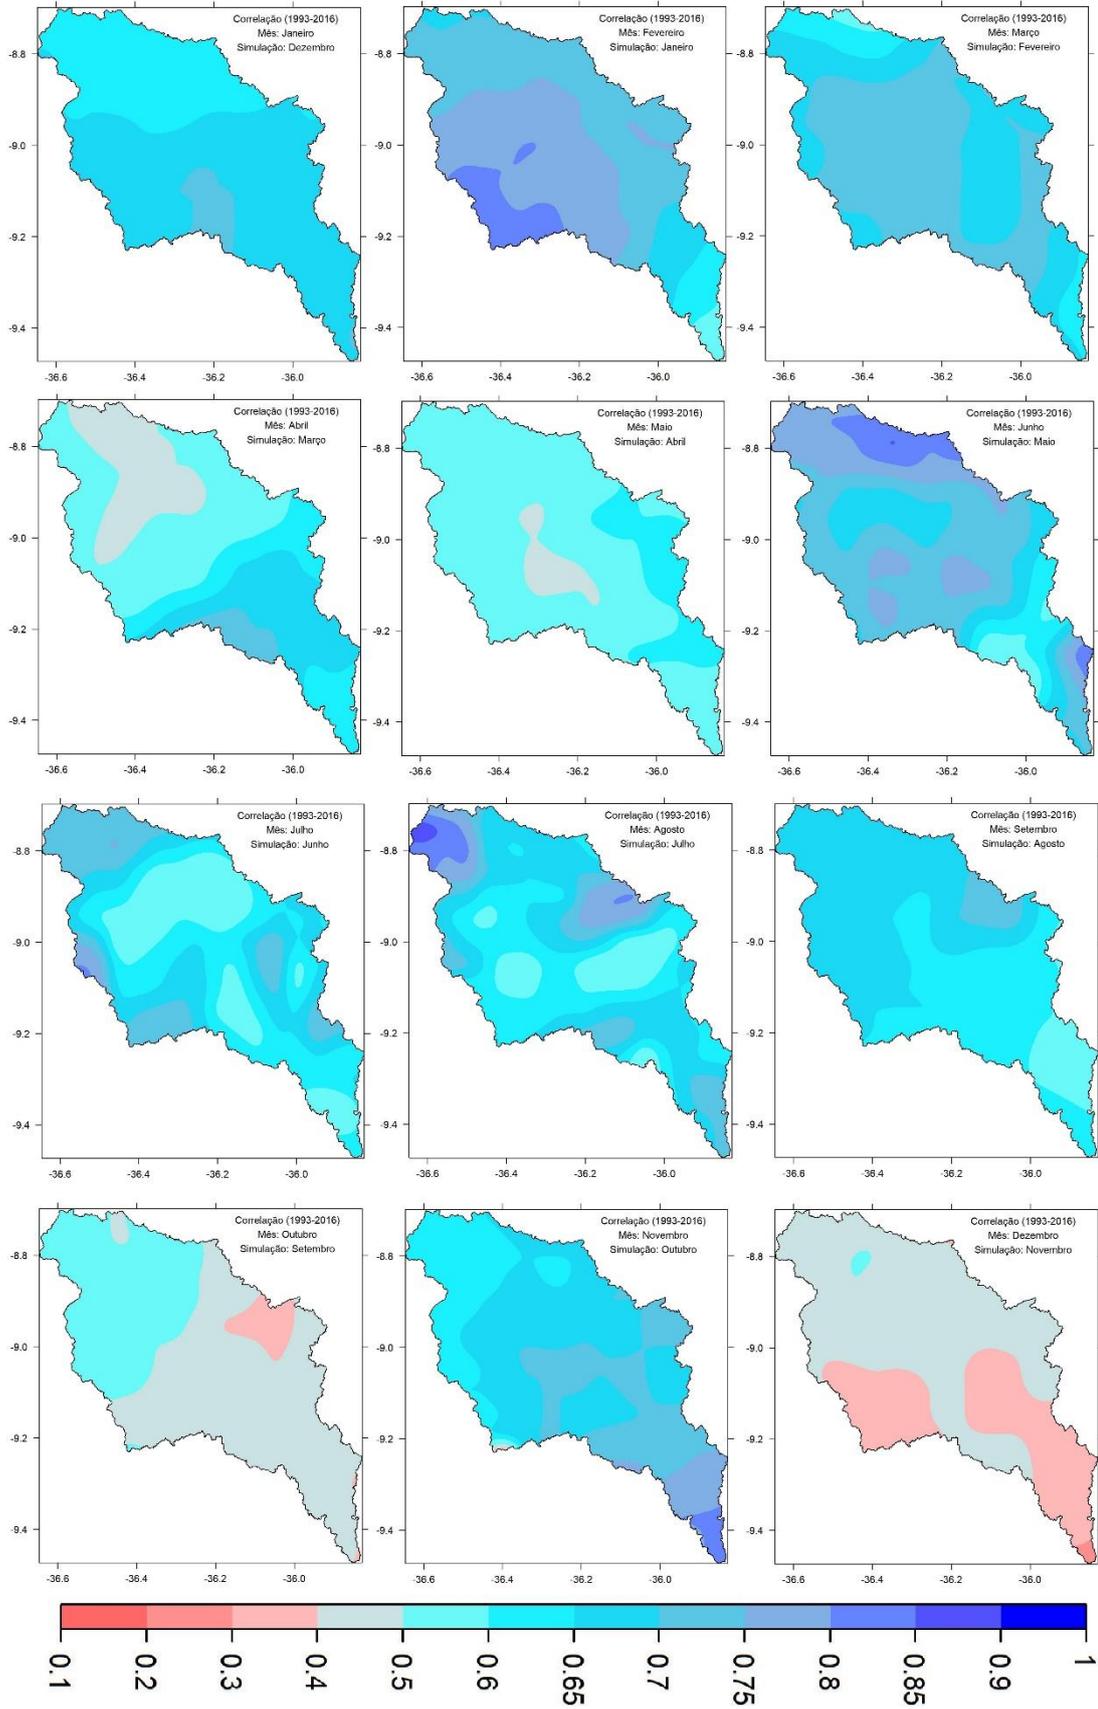
A previsão por conjuntos (ensemble em seu termo em inglês) é uma forma conhecida de melhorar a performance de previsões, por meio da imposição de diferentes condições de inicialização aos modelos. Após obtenção de diferentes previsões, chamadas de membros, a agregação desses diferentes resultados em um resultado único que pode se dar por diversos artifícios matemáticos (VAN DEN DOOL, 2006). No entanto, é consenso entre especialistas que uma das maneiras mais eficientes de obter o resultado único a partir de um conjunto de previsões se dá pela média simples de todas as previsões (ESQUIVEL-MUELBERT et al., 2019).

De certo que é salutar em um sistema operacional de previsão do clima se antever com máximo de tempo sobre o prognóstico de chuvas acumuladas para meses à frente. Mas, vimos que não há uma linearidade quanto a destreza das previsões, embora predominem entre os meses melhores previsões no realizadas no mês imediatamente anterior, houve para outros meses melhores previsões entre todas as realizadas com até cinco meses de antecedência, como bem demonstrado também na análise dos diagramas de Taylor.

Logo, optou-se por gerar uma previsão a partir da média de todas as cinco previsões para cada mês e recalcular as correlações, o que, de fato, aumentou consideravelmente os valores das mesmas. Este resultado é muito importante, pois demonstra que, por exemplo, se algum órgão de meteorologia operacional de Alagoas ou Pernambuco que pretenda prever o acumulado de chuvas na BHM, deve de preferência realizar as cinco previsões com condições iniciais de cada mês retrógrado e após isso, aplicar uma média simples a essas previsões.

A Figura 27 mostra as correlações obtidas do conjunto para cada mês do ano, onde percebe-se a considerável melhoria dos valores de correlações obtidos entre a simulação por conjunto e as observações. Com exceção dos meses de outubro e dezembro, nenhum outro mês possui áreas com correlações inferiores a 0,4, ou seja, sem significância estatística. Fevereiro e junho destacam-se com áreas de correlações superiores a 0,8, com o máximo de correlação observada no norte da BHM em agosto, entre 0,85 e 0,9.

Figura 27 – Correlações entre observações e previsões por conjunto para cada mês do ano.



Fonte: autor.

4.7 Previsões por conjunto para o ano de 2020 – estudo de caso.

Utilizamos a ACC para gerar previsões por conjunto para o ano de 2020, haja visto que as correlações entre previsões e observações terem melhorado substancialmente com a aplicação dessa técnica. As Figura 28 a Figura 39 mostram, para janeiro a dezembro de 2020, a precipitação acumulada mensal e a prevista para o mês, e as respectivas anomalias em relação à média do período 1993-2016, período de hindcast usado para recalibrar as previsões do MFS7 usando ACC com o CPT.

Para janeiro (Figura 28), a previsão foi de desvios negativos em toda BHM, o que se concretizou em sua maior área com exceção do norte da bacia onde o desvio de chuva foi positivo. Para fevereiro (Figura 29), foi previsto desvios levemente positivos nos extremos norte e sul da bacia, e acumulados próximos a média na grande porção central da BHM. Os desvios observados concordaram com a previsão para o norte e sul da bacia, embora com anomalias positivas mais intensas e de maior extensão, enquanto no centro da BHM foram observados desvios levemente negativos.

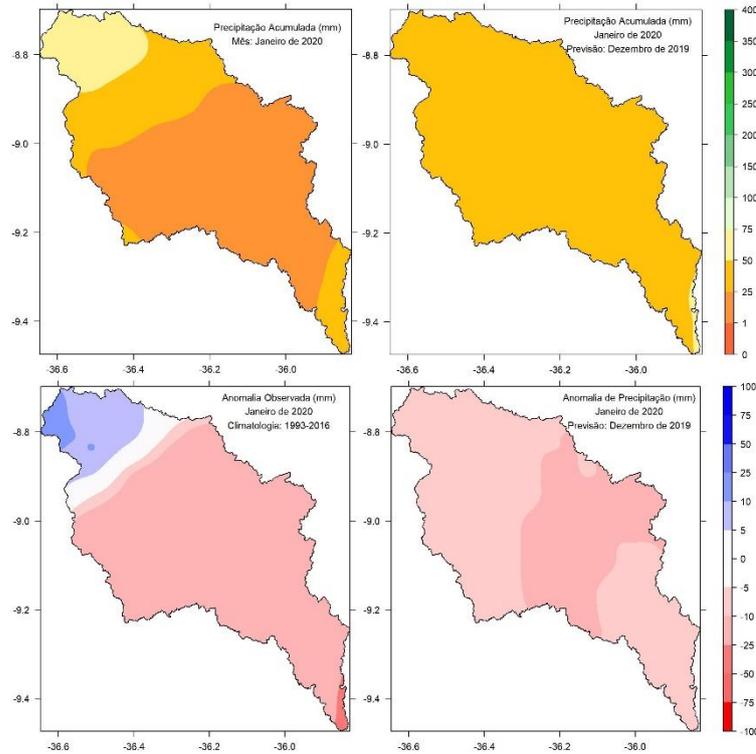
A Figura 30, para março, mostra que os desvios positivos previstos para a BHM ocorreram, embora com valores que subestimaram os valores reais. Característica similar à de março aconteceu em abril (Figura 31), com previsão generalizada de desvios positivos na BHM principalmente mais à sul, embora os desvios observados tenham sido mais elevados. Em maio (Figura 32), a previsão de desvios negativos foi assertiva, embora com menor intensidade que os valores observados. Para junho (Figura 33), mês mais chuvoso da BHM, foram previstos desvios positivos em torno de 100 mm no leste da BHM, o que ocorreu nessa área, embora o modelo não tenha previsto o acentuado déficit de chuvas no oeste da bacia.

Para julho (Figura 34), os desvios previstos foram mais suaves do que os observados, embora concordantes na maior parte das áreas. Para agosto (Figura 35), previmos acumulados de chuvas inferiores à média, o que ocorreu, mas de forma mais intensa, previsão está muito parecida com a de setembro (Figura 36), embora para esse mês os desvios negativos observados tenham sido menos subestimados pelo modelo. Para outubro (Figura 37), o modelo previu leves desvios negativos para o centro-norte da BHM, e os desvios observados embora também negativos, foram mais intensos no centro-sul da bacia. Por fim em novembro (Figura 38) o modelo previu leves desvios positivos da precipitação acumulada, sinal esse captado em decorrência da prevalência de desvios positivos observados, embora mais intensos que os previstos pelo modelo. Em dezembro (Figura 39), mês muito seco, o modelo não conseguiu se afastar da média, prevendo basicamente os valores climatológicos desse mês, e a observação mostrou que predominou na BHM acumulados inferiores à média.

Estes resultados são animadores, onde de forma determinística analisando acumulados e desvios mensais, percebe-se que a metodologia imposta a previsão mensal na BHM pode ser utilizada de forma operacional, pois os resultados mostraram prevalência de acertos e capacidade do modelo em captar o sinal das acumulações, embora em muitos casos os desvios observados tenham sido subestimados pelo modelo. Essa não é uma característica incomum, na verdade, é frequente na literatura científica o esforço mundial em desenvolver modelos que consigam prever valores que consigam se afastar da média climatológica e captar extremos (DA ROCHA JÚNIOR et al., 2021).

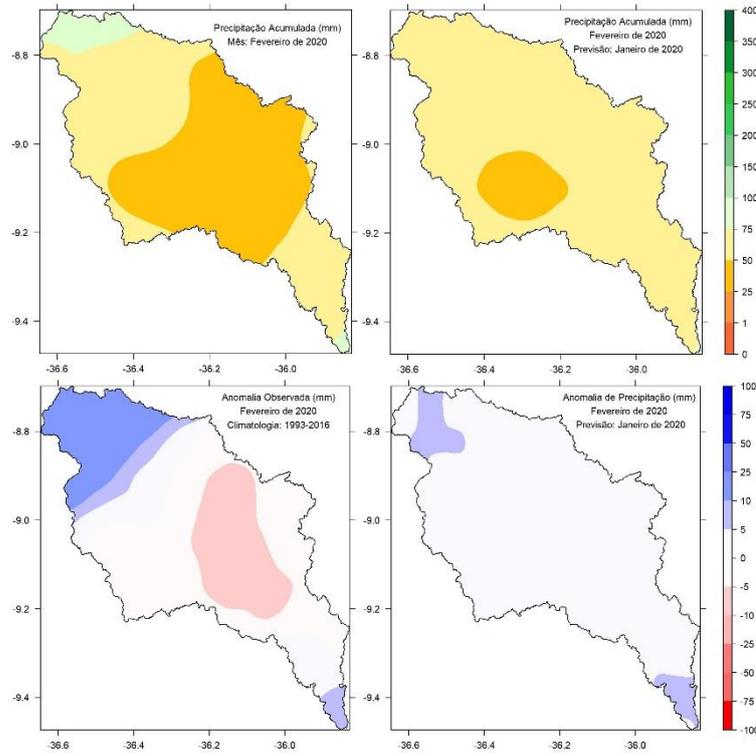
A previsão climática para a BHM é importante e deve ser sempre desenvolvida, devido a seu histórico de períodos secos e úmidos que por vezes trouxeram danos a sua população e não são eficientemente previstas (COMIN et al., 2021). Da Rocha Júnior et al., (2021), mostraram que a região onde está inserida a BHM possui tendência recente de aumento das chuvas no trimestre mais seco do ano (de novembro a janeiro), de redução das chuvas no trimestre de transição entre o período seco e úmido (trimestre de fevereiro a abril), e de aumento das precipitações acumuladas no trimestre mais chuvoso do ano (maio a julho), além disso, demonstraram que essa região está sujeita a um período de retorno de secas em torno de 12 meses, com secas moderadas prevalecendo nessa área. Estas características, por si só, demonstram que os resultados dessa pesquisa podem ser usados para operacionalizar um sistema de previsão climática para a BHM.

Figura 28 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para janeiro de 2020 (painel inferior).



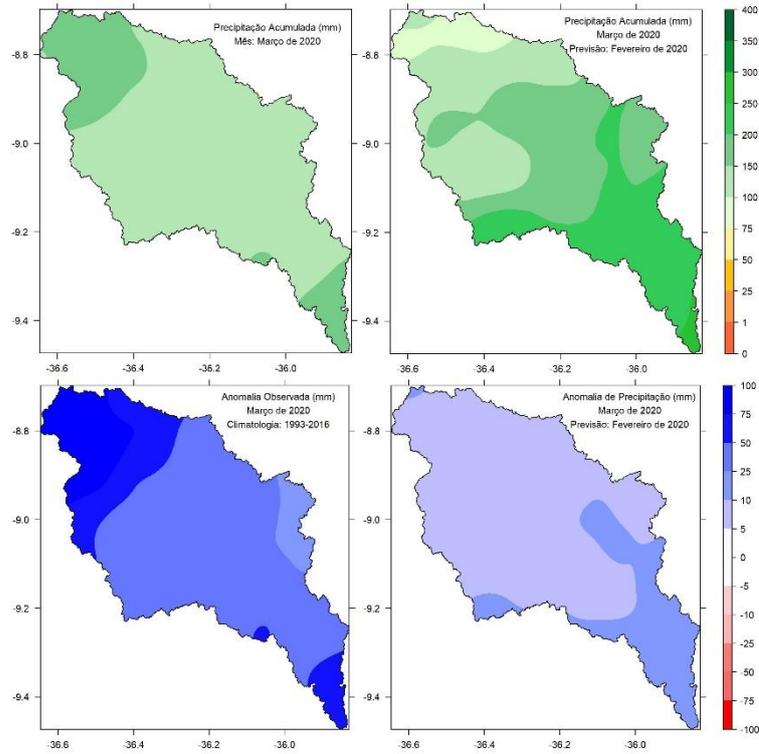
Fonte: autor.

Figura 29 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para fevereiro de 2020 (painel inferior).



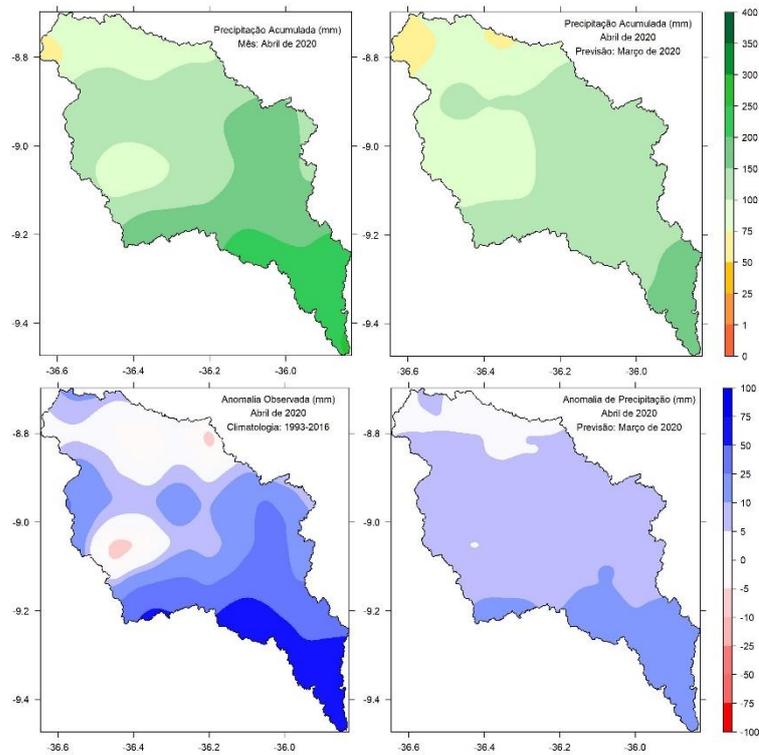
Fonte: autor.

Figura 30 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para março de 2020 (painel inferior).



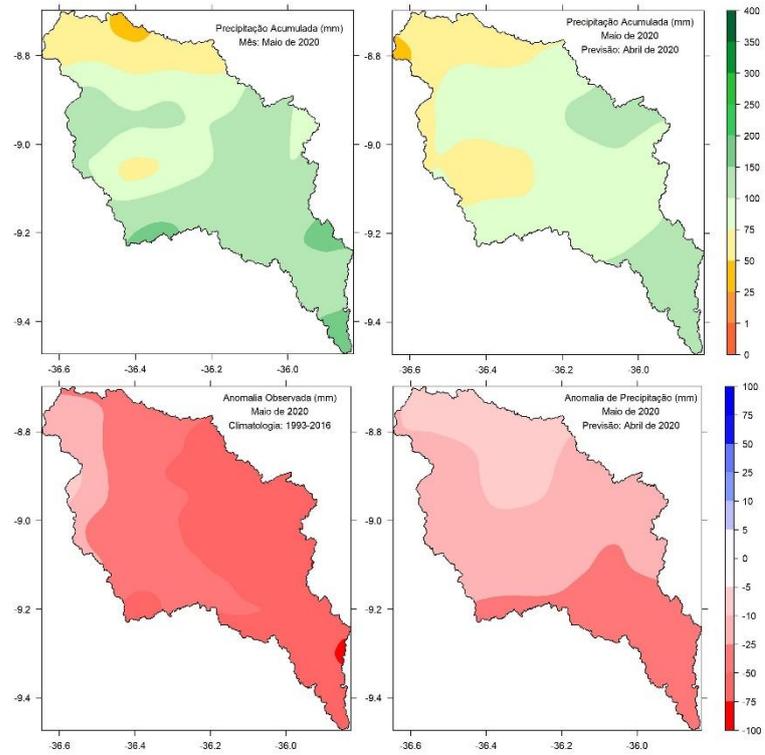
Fonte: autor.

Figura 31 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para abril de 2020 (painel inferior).



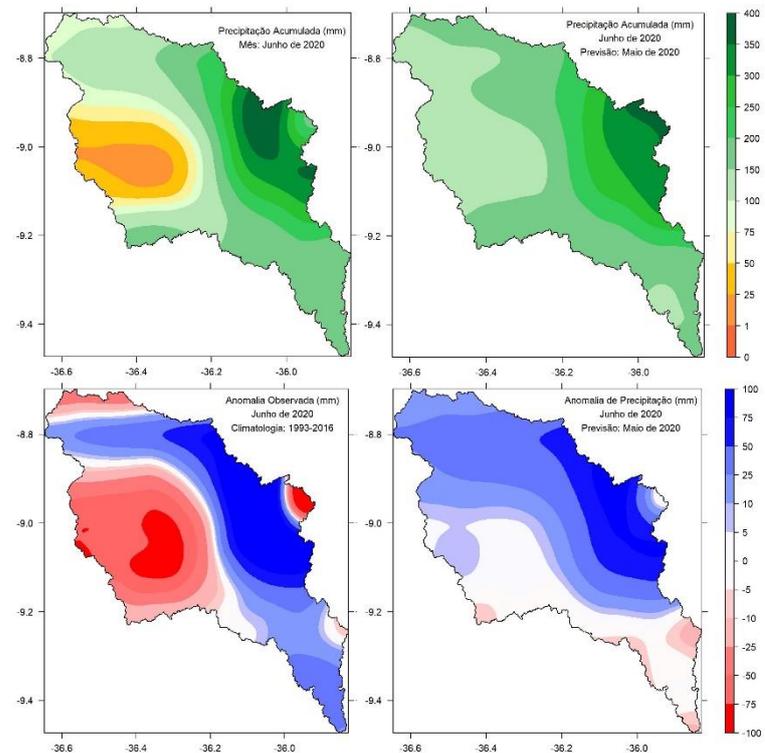
Fonte: autor.

Figura 32 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para maio de 2020 (painel inferior).



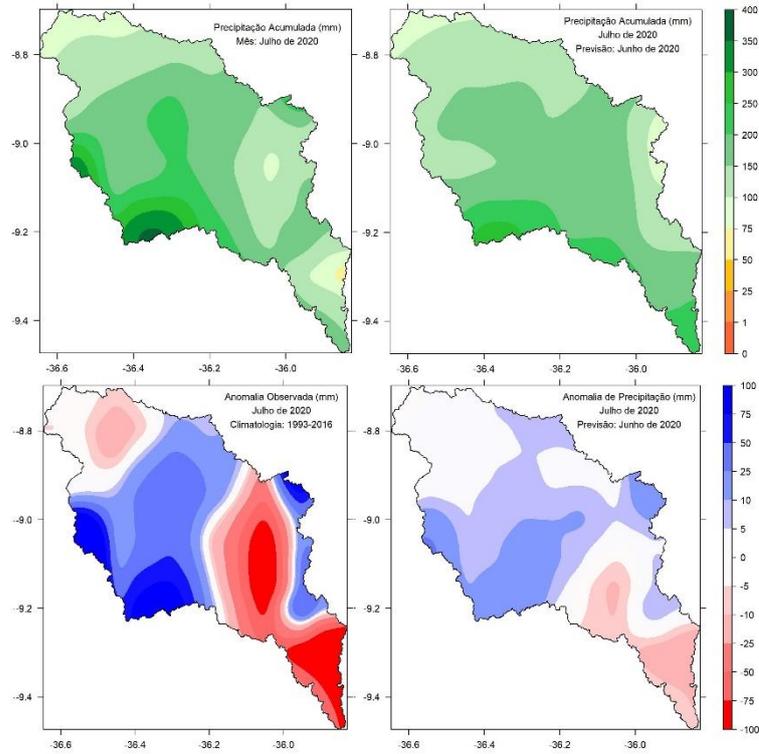
Fonte: autor.

Figura 33 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para junho de 2020 (painel inferior).



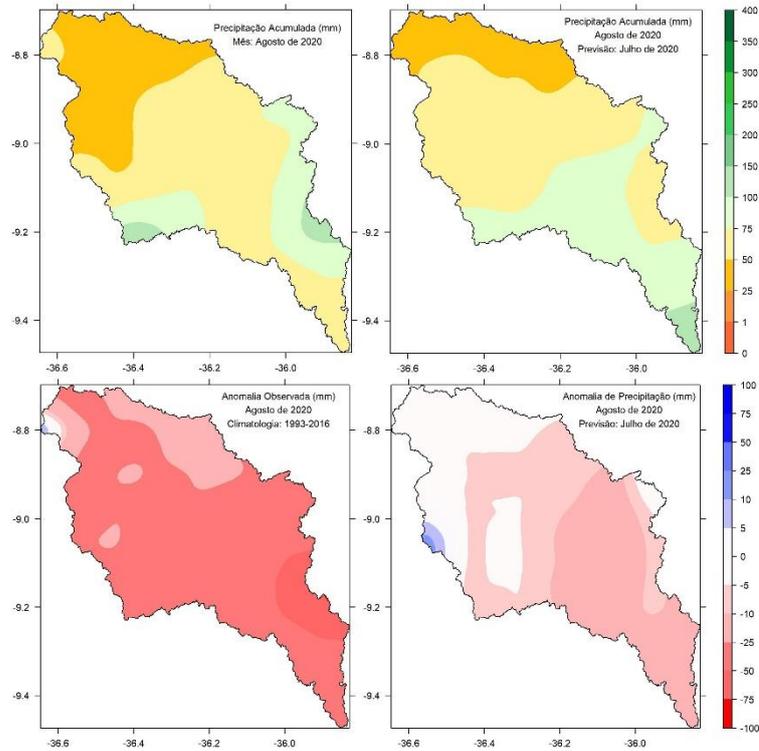
Fonte: autor.

Figura 34 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para julho de 2020 (painel inferior).



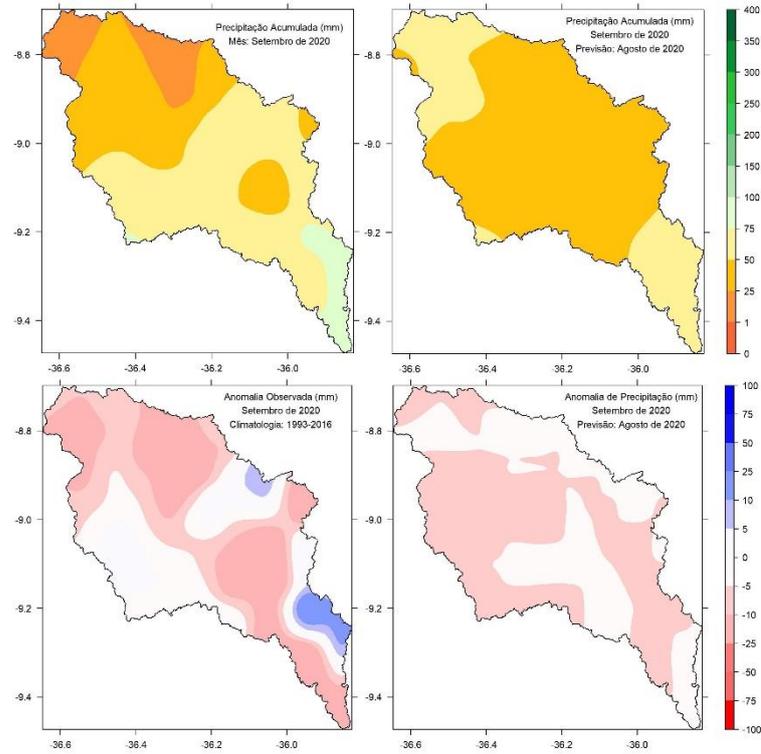
Fonte: autor.

Figura 35 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para agosto de 2020 (painel inferior).



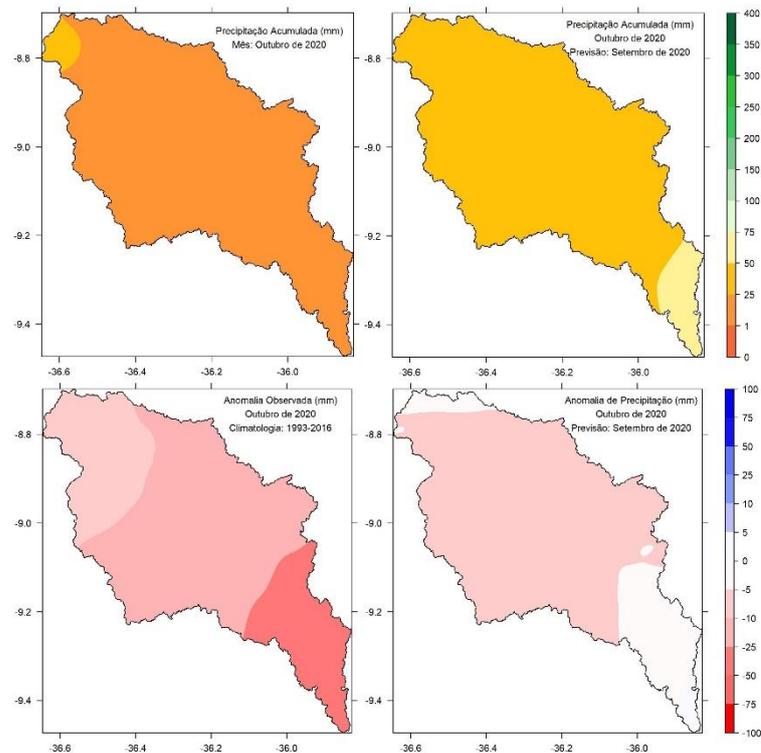
Fonte: autor.

Figura 36 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para setembro de 2020 (painel inferior).



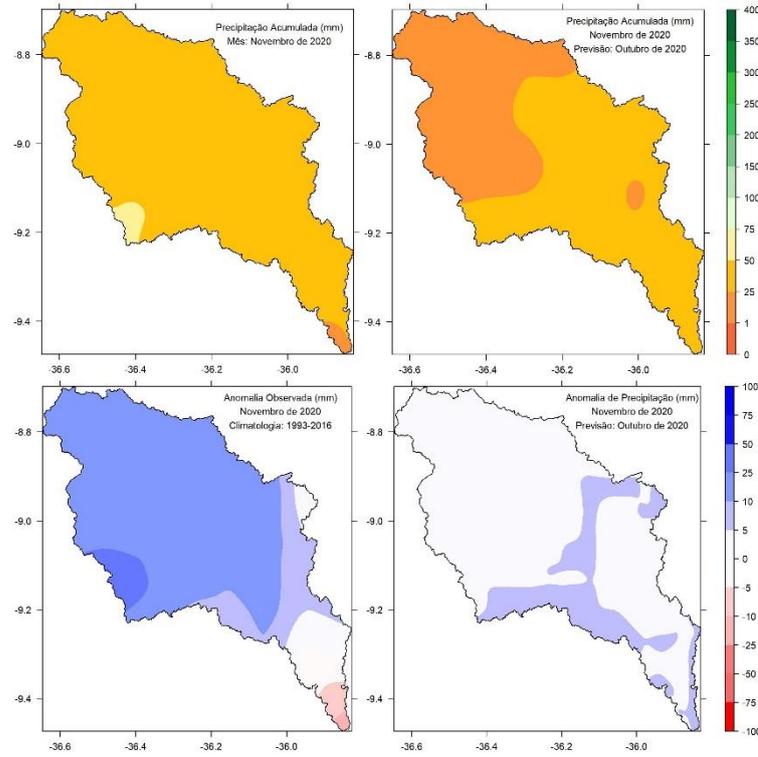
Fonte: autor.

Figura 37 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para outubro de 2020 (painel inferior).



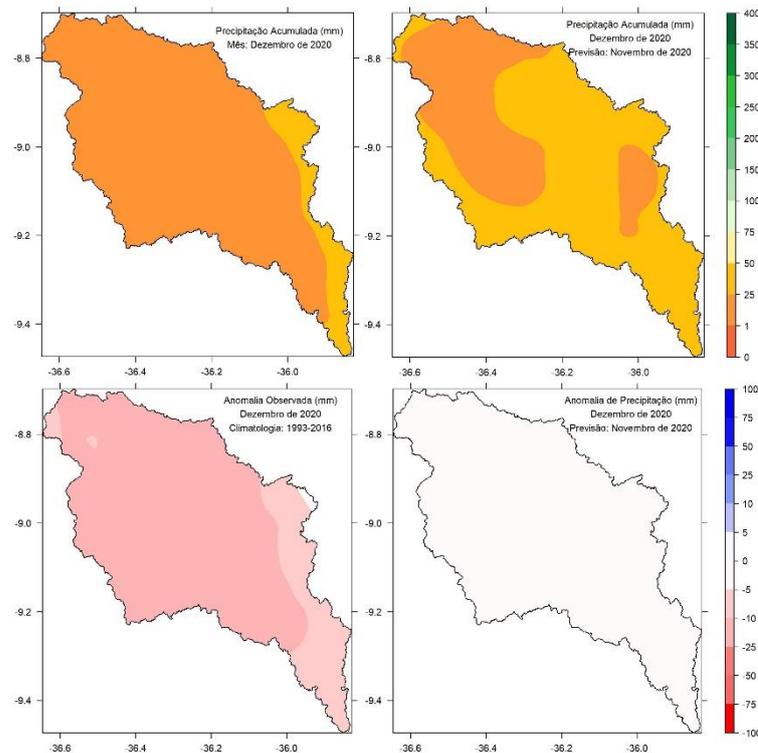
Fonte: autor.

Figura 38 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para novembro de 2020 (painel inferior).



Fonte: autor.

Figura 39 – Precipitação acumulada observada e prevista (painel superior), e anomalias observada e prevista para dezembro de 2020 (painel inferior).



Fonte: autor.

5 CONCLUSÕES

A região Nordeste é caracterizada por grande variabilidade climática interanual, com longos períodos secos e úmidos intercalados. Diante desse cenário, faz-se cada vez mais necessário o desenvolvimento de sistemas operacionais de previsão climática subsazonal.

Nesta pesquisa detalha-se uma iniciativa de avaliar e operacionalizar as previsões climáticas mensais do MFS7 para a BHM, localizada na divisa dos estados de Pernambuco e Alagoas. Implementou-se um modelo empírico de calibração das previsões brutas do modelo baseado na técnica de ACC, que permite ajustar previsões de um modelo climático global em relação a séries de dados observados de uma região de interesse.

Estudos citados no decorrer da dissertação mostraram que modelos empíricos de naturezas diversas tem se mostrado cada vez mais competitivos em comparação a previsões climáticas derivadas unicamente de modelos dinâmicos.

O MFS7 fornece um período de *hindcast* de 1993 a 2016, e previsões a partir de 2017. Calibramos o período de *hindcast* do MFS7 confrontando as previsões do modelo em uma área de domínio superior à da BHM, com as séries extraídas do CHIRPS para essa bacia com resolução de $0,05^\circ$, totalizando 323 séries temporais de precipitação cumulada. Os dados do CHIRPS foram validados mediante comparação com postos pluviométricos da ANA na BHM, demonstrando alta correlação e erros dentro da normalidade.

Para cada mês de interesse, geramos cinco previsões inicializadas nos meses anteriores. A análise de correlações, erros e diagramas de Taylor mostraram que não há uma linearidade entre essas previsões, com as melhores previsões ocorrendo de forma aleatória quanto as defasagens das previsões. Para sanar esse problema, aplicamos a técnica da previsão por conjuntos, gerando uma previsão única a partir da média das cinco previsões geradas para cada mês. O resultado demonstrou aumento significativo dos valores das correlações entre a previsões e observações.

Uma vez demonstrado esse potencial da previsão simples por conjunto, mostramos um estudo de caso para o ano de 2020, comparando acumulados e desvios previstos com acumulados e desvios observados em relação a climatologia do período 1993-2016, cujos resultados apontam para o potencial de captura do sinal da acumulação, anomalias positivas ou negativas, pelo modelo calibrado, no entanto, ainda com dificuldade em simular a real magnitude dos desvios observados, subestimando na maior parte dos meses seus valores.

6 REFERENCIAS BIBLIOGRAFICAS

- AL-ACHI, A. **The Student's t-Test: A Brief Description**. [s.l: s.n.].
- ALVES, A. L. **Efeito de teleconexões climáticas na variabilidade espaço-temporal dos índices de disponibilidade hídrica em uma bacia hidrográfica sob transição climática (Tropical/Semiárido)**. [s.l.] Universidade Federal de Alagoas, 2016.
- ARAME TALL; JEANNE Y. COULIBALY; MOUSTAPHA DIOP. Do climate services make a difference? A review of evaluation methodologies and practices to assess the value of climate information services for farmers: Implications for Africa. **Climate Services**, 2018.
- 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, n. 9, p. 1825–1850, set. 1987.
- BARNSTON, A. G. Linear Statistical Short-Term Climate Predictive Skill in the Northern Hemisphere. **Journal of Climate**, v. 7, n. 10, p. 1513–1564, out. 1994.
- BARNSTON, A. G. et al. Verification of the first 11 years of IRI's seasonal climate forecasts. **Journal of Applied Meteorology and Climatology**, v. 49, n. 3, p. 493–520, mar. 2010.
- 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, 1 out. 2017.
- BATTÉ, L. et al. **Documentation of the METEO-FRANCE seasonal forecasting system 7 C3S_330_Météo-France-Operational Seasonal Forecasts**. [s.l: s.n.].
- BELJAARS, A. C. M.; BROWN, A. R.; WOOD, N. A new parametrization of turbulent orographic form drag. **Quarterly Journal of the Royal Meteorological Society**, v. 130, n. 599, p. 1327–1347, 1 abr. 2004.
- BOROVIKOV, A. et al. GEOS-5 seasonal forecast system. **Climate Dynamics**, v. 53, n. 12, p. 7335–7361, 2019.
- BROWNE, M. W. Cross-Validation Methods. **Journal of Mathematical Psychology**, v. 44, n. 1, p. 108–132, mar. 2000.
- CEGLAR, A.; TORETI, A. Seasonal climate forecast can inform the European agricultural sector well in advance of harvesting. **npj Climate and Atmospheric Science**, v. 4, n. 1, 1 dez. 2021.
- COELHO, C. A. S. et al. **Toward an Integrated Seasonal Forecasting System for South America**. [s.l: s.n.]. Disponível em: <<http://www.ons.org.br>>.

- COELHO, C. A. S. et al. **Toward an Integrated Seasonal Forecasting System for South America**. [s.l.: s.n.]. Disponível em: <<http://www.ons.org.br>>.
- COELHO, C. A. S.; COSTA, S. M. S. **Challenges for integrating seasonal climate forecasts in user applications**. *Current Opinion in Environmental Sustainability*, dez. 2010.
- COMIN, A. N. et al. Extreme rainfall event in the Northeast coast of Brazil: a numerical sensitivity study. *Meteorology and Atmospheric Physics*, v. 133, n. 2, p. 141–162, 2021.
- COMMAR, L. F. S. A. **Avaliação da previsão climática do início da estação chuvosa no Oeste da Bahia**. [s.l.] Universidade Federal de Viçosa, 2020.
- COSTA, D. D. **Previsão Hidrológica de Longo-Prazo baseada em Componentes Climáticas em Bacias Hidrográficas Semiáridas / Tropicais Maceió Previsão Hidrológica de Longo-Prazo baseada em Componentes Climáticas em Bacias Hidrográficas Semiáridas / Tropicais Maceió**. [s.l.] Universidade Federal de Alagoas, 2014.
- COSTA, J. C. et al. VALIDAÇÃO DOS DADOS DE PRECIPITAÇÃO ESTIMADOS PELO CHIRPS PARA O BRASIL. *Revista Brasileira de Climatologia*, v. 24, 11 jun. 2019.
- COUTINHO, E. C., FISCH, G. Distúrbios Ondulatórios de Leste (Dols) na Região do Centro de Lançamento de Alcântara-MA. *Revista Meteorologia, Brasileira de*, 2007.
- CUXART, J.; BOUGEAULT, P.; REDELSPERGER, J.-L. A turbulence scheme allowing for mesoscale and large-eddy simulations. *Quarterly Journal of the Royal Meteorological Society*, v. 126, n. 562, p. 1–30, 1 jan. 2000.
- DA ROCHA JÚNIOR, R. L. et al. An empirical seasonal rainfall forecasting model for the northeast region of brazil. *Water (Switzerland)*, v. 13, n. 12, 1 jun. 2021a.
- DA ROCHA JÚNIOR, R. L. et al. An empirical seasonal rainfall forecasting model for the northeast region of brazil. *Water (Switzerland)*, v. 13, n. 12, 1 jun. 2021b.
- DA SILVA, D. F. **Análise de aspectos climatológicos, agroeconômicos, ambientais e de seus efeitos sobre a Bacia Hidrográfica do rio Mundaú (AL e PE)**. [s.l.] UNIVERSIDADE FEDERAL DE CAMPINA GRANDE – UFCG, 2009.
- DARON, J.; STAINFORTH, D. Assessing pricing assumptions for weather index insurance in a changing climate. *Climate Risk Management*, v. 1, 11 fev. 2014.
- DE SOUZA FERREIRA, G. W. R. M. S. D. R. R. P. Vórtices Ciclônicos de Altos Níveis nas Cercanias do Nordeste do Brasil: Climatologia e Análise da Vorticidade Potencial Isentrópica. *Anuário do Instituto de Geociências*, v. 42, p. 568–585, 2020.
- DECHARME, B. et al. Recent Changes in the ISBA-CTRIP Land Surface System for Use in the CNRM-CM6 Climate Model and in Global Off-Line Hydrological Applications. *Journal of Advances in Modeling Earth Systems*, v. 11, n. 5, p. 1207–1252, 1 maio 2019.

- DEE, D. ; FASULLO, J. ; SHEA, D. ; W. J. **The climate data guide: atmospheric reanalysis: overview & comparison tables**. Disponível em: <m <https://climatedataguide.ucar.edu/climate-data/atmospheric-reanalysisoverview-comparison-tables>>. Acesso em: 10 abr. 2023.
- DÉQUÉ, M. et al. The ARPEGE/IFS atmosphere model: a contribution to the French community climate modelling. **Climate Dynamics**, v. 10, n. 4, p. 249–266, 1994.
- DOS SANTOS, S. R. Q.; CUNHA, A. P. M. DO A.; RIBEIRO-NETO, G. G. AVALIAÇÃO DE DADOS DE PRECIPITAÇÃO PARA O MONITORAMENTO DO PADRÃO ESPAÇO-TEMPORAL DA SECA NO NORDESTE DO BRASIL. **Revista Brasileira de Climatologia**, v. 25, 9 ago. 2019.
- DUBREUIL, V. et al. Os tipos de climas anuais no Brasil : uma aplicação da classificação de Köppen de 1961 a 2015. **Confins**, n. 37, 24 set. 2018.
- ESCADA, P. et al. Climate services in Brazil: Past, present, and future perspectives. **Climate Services**, v. 24, p. 100276, 2021.
- ESQUIVEL-MUELBERT, A. et al. Compositional response of Amazon forests to climate change. **Global Change Biology**, v. 25, n. 1, p. 39–56, 8 jan. 2019.
- FAGUNDES, H. DE O. et al. Sediment modeling of a large-scale basin supported by remote sensing and in-situ observations. **CATENA**, v. 190, p. 104535, jul. 2020.
- FERREIRA, A. G.; MELLO, N. G. DA S. Principais Sistemas Atmosféricos Atuantes Sobre A Região Nordeste Do Brasil E A Influência Dos Oceanos Pacífico E Atlântico No Clima Da Região. **Revista Brasileira de Climatologia**, 2005.
- FERREIRA DA COSTA, P. N. **Verificação do modelo de circulação geral da atmosfera do CPTEC/COLA: ciclo hidrológico e processos de superfície**. [s.l: s.n.].
- FRAGOSO JÚNIOR, C. R.; PEDROSA, V. A.; SOUZA, V. C. Reflexões Sobre a Cheia de Junho de 2010 nas Bacias do Rio Mundaú e Paraíba. **XVI Simpósio Brasileiro de Recursos Hídricos**, p. 1–20, 2010.
- FUNK, C. et al. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. **Scientific Data**, v. 2, n. 1, p. 150066, 8 dez. 2015.
- GELETA, C. D.; DERESSA, T. A. Evaluation of Climate Hazards Group InfraRed Precipitation Station (CHIRPS) <scps>satellite-based</scps> rainfall estimates over Finchaa and Neshe Watersheds, Ethiopia. **Engineering Reports**, v. 3, n. 6, 22 jun. 2021.
- GOMES, H. B. et al. WRF Sensitivity for Seasonal Climate Simulations of Precipitation Fields on the CORDEX South America Domain. **Atmosphere**, v. 13, n. 1, 1 jan. 2022.

- GU, H. et al. High-resolution ensemble projections and uncertainty assessment of regional climate change over China in CORDEX East Asia. **Hydrology and Earth System Sciences**, v. 22, n. 5, p. 3087–3103, 30 maio 2018.
- GUEREMY, J. F. A continuous buoyancy based convection scheme: One- and three-dimensional validation. **Tellus, Series A: Dynamic Meteorology and Oceanography**, v. 63, n. 4, p. 687–706, ago. 2011.
- HAMAKAWA, P. J. **Análises multivariadas e de séries temporais de elementos meteorológicos e de parâmetros fenológicos do cacauero (Theobroma cacao L.) sob diferentes estratégias de irrigação**. [s.l.] Universidade Federal de Viçosa, 2002.
- HANSSEN-BAUER, I. et al. Statistical downscaling of climate scenarios over Scandinavia. **Climate Research**, v. 29, p. 255–268, 2005.
- 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, abr. 1984.
- 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.
- HERSBACH, H. et al. The ERA5 global reanalysis. **Quarterly Journal of the Royal Meteorological Society**, v. 146, n. 730, p. 1999–2049, 1 jul. 2020.
- HOSSAIN, M. et al. Application of extreme learning machine for short term output power forecasting of three grid-connected PV systems. **Journal of Cleaner Production**, v. 167, p. 395–405, nov. 2017.
- HUFFMAN, G. J. et al. The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-Global, Multiyear, Combined-Sensor Precipitation Estimates at Fine Scales. **Journal of Hydrometeorology**, v. 8, n. 1, p. 38–55, 1 fev. 2007.
- JOHNSON, S. J. et al. SEAS5: The new ECMWF seasonal forecast system. **Geoscientific Model Development**, v. 12, n. 3, p. 1087–1117, 22 mar. 2019.
- KAYANO, M. T.; ANDREOLI, R. V. Relations of South American summer rainfall interannual variations with the Pacific Decadal Oscillation. **International Journal of Climatology**, v. 27, n. 4, p. 531–540, 30 mar. 2007.
- KHARIN, V. V. et al. Statistical adjustment of decadal predictions in a changing climate. **Geophysical Research Letters**, v. 39, n. 19, 16 out. 2012.
- KIRTMAN, B. P. et al. 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.

- LARSON, J.; JACOB, R.; ONG, E. The Model Coupling Toolkit: A New Fortran90 Toolkit for Building Multiphysics Parallel Coupled Models. **The International Journal of High Performance Computing Applications**, v. 19, n. 3, p. 277–292, 1 ago. 2005.
- LEE, J. C. K. et al. Weather Prediction for Singapore—Progress, Challenges, and Opportunities. **Meteorology**, v. 1, n. 4, p. 394–401, 9 out. 2022.
- LOESCH, C. H. M. **Métodos estatísticos multivariados**. [s.l: s.n.].
- LOPEZ, P. Implementation and validation of a new prognostic large-scale cloud and precipitation scheme for climate and data-assimilation purposes. **Quarterly Journal of the Royal Meteorological Society**, v. 128, n. 579, p. 229–257, 1 jan. 2002.
- LÚCIO, P. S. et al. **UM MODELO ESTOCÁSTICO COMBINADO DE PREVISÃO SAZONAL PARA A PRECIPITAÇÃO NO BRASIL** *Revista Brasileira de Meteorologia*. [s.l: s.n.].
- LYRA, M. J. A.; FREITAS, I. G. F.; SANTIAGO, D. B. **Revista Brasileira de Geografia Física v.** [s.l: s.n.].
- MANZANAS, R. et al. Dynamical and statistical downscaling of seasonal temperature forecasts in Europe: Added value for user applications. **Climate Services**, v. 9, p. 44–56, 2018.
- MARIOTTI, A. et al. Windows of opportunity for skillful forecasts subseasonal to seasonal and beyond. **Bulletin of the American Meteorological Society**, v. 101, n. 5, p. E608–E625, 1 maio 2020.
- MARIOTTI, A.; RUTI, P. M.; RIXEN, M. Progress in subseasonal to seasonal prediction through a joint weather and climate community effort. **npj Climate and Atmospheric Science**, v. 1, n. 1, 1 dez. 2018.
- MARONNA, R. Alan Julian Izenman (2008): Modern Multivariate Statistical Techniques: Regression, Classification and Manifold Learning. **Statistical Papers**, v. 52, n. 3, p. 733–734, 25 ago. 2011.
- MARTINS, E. S. P. R.; VASCONCELOS JÚNIOR, F. DAS C. O clima da Região Nordeste entre 2009 e 2017: monitoramento e previsão. 2017.
- MEDEIROS, R. M. Método da classificação climática de Köppen e Thornthwaite aplicado ao município de Bom Jesus - PI, Brasil. **Brazilian Journal of Agroecology and Sustainability**, 6 jan. 2020.
- MERRYFIELD, W. J. et al. Current and emerging developments in subseasonal to decadal prediction. **Bulletin of the American Meteorological Society**, v. 101, n. 6, p. E869–E896, 26 jun. 2020.

- MERTLER, C. A.; VANNATTA, R. A. **Advanced and Multivariate Statistical Methods: Practical Application and Interpretation.** [s.l.: s.n.].
- MÉTÉO-FRANCE; BATTÉ, L. **Documentation of the METEO-FRANCE seasonal forecasting system 7: C3S_330_Météo-France-Operational Seasonal Forecasts.** [s.l.: s.n.].
- MILLER, S. et al. Analysis of a short-term and a seasonal precipitation forecast over kenya. **Atmosphere**, v. 12, n. 11, 1 nov. 2021.
- MONTE, B. E. O. **Mapeamento de inundações no município de Rio Largo (AL).** [s.l.] Universidade Federal de Alagoas, 2013.
- MORAIS, M. D. C. Vórtices ciclônicos de altos níveis que atuam no Nordeste do Brasil: estudo observacional e numérico. **Instituto Nacional de pesquisas espaciais-INPE**, v. 1, p. 231, 2016.
- MOURA, H. P. et al. A Comparative Study Of Box Jenkins Models And Artificial Neural Networks In Forecasting Pluviometric Flows And Precipitations Of Araguaia-Tocantins Basin/Brazil. **2019**, [s.d.].
- ORDOÑEZ, L. et al. Applying agroclimatic seasonal forecasts to improve rainfed maize agronomic management in Colombia. **Climate Services**, v. 28, p. 100333, 2022.
- OSGOOD, D. E. et al. **Integrating Seasonal Forecasts and Insurance for Adaptation among Subsistence Farmers: The Case of Malawi.** [s.l.: s.n.]. Disponível em: <<http://econ.worldbank.org>>.
- OSMAN, M.; COELHO, C. A. S.; 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.
- OTTO, M. **Chemometrics: Statistics and Computer Application in Analytical Chemistry.** 3. ed. [s.l.: s.n.].
- PICARD, R. R.; COOK, R. D. Cross-Validation of Regression Models. **Journal of the American Statistical Association**, v. 79, n. 387, p. 575–583, 1 set. 1984.
- PINHEIRO, J. U. **Vórtices ciclônicos em altos níveis sobre o nordeste do brasil e mudanças climáticas: análise para o clima atual e cenários.** [s.l.] Universidade Federal do Rio Grande do Norte, 2015.
- PROTÁSIO, T. DE P. et al. **Correlações canônicas entre as características químicas e energéticas de resíduos lignocelulósicos.** [s.l.: s.n.].
- RABELO, D. R.; SANTOS, M. R. DA S.; FILHO, M. R. P. D. S. Análise comparativa dos dados pluviométricos de satélite e de superfície em bacia hidrográfica semiárida. **Revista Brasileira de Sensoriamento Remoto**, v. 3, 2022.

- RASMUSSESON, E. M.; CARPENTER, T. H. Variations in Tropical Sea Surface Temperature and Surface Wind Fields Associated with the Southern Oscillation/El Niño. **Monthly Weather Review**, v. 110, n. 5, p. 354–384, maio 1982.
- REBOITA, M. S. et al. Previsão Climática Sazonal para o Brasil Obtida Através de Modelos Climáticos Globais e Regional. **Revista Brasileira de Meteorologia**, v. 33, n. 2, p. 207–224, jun. 2018.
- RIBEIRO FILHO, J. G. **Aplicações da Técnica de Análise de Correlações Canônicas na Previsão Climática Sazonal no Ceará**. [s.l.] Universidade Estadual do Ceará, 2009.
- RIBEIRO, S. S. **Métodos Computacionais Aplicados À Agricultura: Python & Weka**. [s.l.: s.n.].
- ROSSI, D. M. **Estudo da discinesia escapular por análise de componentes principais aplicada aos dados de cinemática tridimensional escapulotorácica**. Ribeirão Preto: Universidade de São Paulo, 6 ago. 2018.
- RUSTIANA, S. et al. Rainfall prediction of Cimanuk watershed regions with canonical correlation analysis (CCA). **Journal of Physics: Conference Series**, v. 893, p. 012021, out. 2017.
- SAHA, S. et al. The NCEP climate forecast system version 2. **Journal of Climate**, v. 27, n. 6, p. 2185–2208, 2014.
- SALAS MÉLIA, D. A global coupled sea ice–ocean model. **Ocean Modelling**, v. 4, n. 2, p. 137–172, 2002.
- SILVA, D. F. DA; SOUSA, F. DE A. S. DE; KAYANO, M. T. Escalas temporais da variabilidade pluviométrica na bacia hidrográfica do Rio Mundaú. **Revista Brasileira de Meteorologia**, v. 25, n. 3, p. 324–332, set. 2010.
- SILVA, E. H. DE L. et al. Performance Assessment of Different Precipitation Databases (Gridded Analyses and Reanalyses) for the New Brazilian Agricultural Frontier: SEALBA. **Water**, v. 14, n. 9, p. 1473, 4 maio 2022.
- SILVA, S. D. A. et al. Variabilidade espaço-temporal da precipitação na Bacia Hidrográfica do rio Mundaú (PE/AL). **Revista Brasileira de Climatologia**, v. 23, 13 dez. 2018.
- SILVA, W. L.; BARRETO, R. **Modelagem Climática e Vulnerabilidades Setoriais à Mudança do Clima no Brasil**. [s.l.: s.n.]. Disponível em: <<https://www.researchgate.net/publication/305084250>>.
- SILVA, W. L.; DEREZYNSKI, C. P. Climatological Characterization and Observed Trends in Climatic Extremes in the State of Rio de Janeiro. **Anuário do Instituto de Geociências - UFRJ**, v. 37, n. 2, p. 123, 28 nov. 2014.

- SOBREIRO, J. F. F.; STREHER, A. S.; SILVA, T. S. F. Análise comparativa de produtos geoespaciais para monitoramento de precipitação em uma região montanhosa tropical. Em: **Os Desafios da Geografia Física na Fronteira do Conhecimento**. [s.l.] INSTITUTO DE GEOCIÊNCIAS - UNICAMP, 2017. p. 2487–2491.
- SOUZA, R. C. DE et al. Uma Análise na Dragagem do Complexo Estuarino-Lagunar Mundaú/Manguaba em Alagoas através de um Modelo Numérico Hidrodinâmico Bidimensional-Resultados Preliminares. **Revista Brasileira de Recursos Hídricos-RBRH**, v. 9, p. 21–31, 2004.
- STONE, M. Cross-validation: a review ². **Series Statistics**, v. 9, n. 1, p. 127–139, jan. 1978.
- TAYLOR, K. E. Summarizing multiple aspects of model performance in a single diagram. **Journal of Geophysical Research: Atmospheres**, v. 106, n. D7, p. 7183–7192, 16 abr. 2001.
- TIWARI, P. R. et al. Comparison of statistical and dynamical downscaling methods for seasonal-scale winter precipitation predictions over north India. **International Journal of Climatology**, v. 39, n. 3, p. 1504–1516, 15 mar. 2019.
- TUCCI, C. E. M.; LEITE, P.; DIAS, S. **Previsão de médio prazo da afluência de reservatórios com base na previsão climática Evaluation of Easterly Wave Disturbances on the tropical South Atlantic in the present climate using the CMIP6 models View project Combining SWOT observations with modelling for South America water systems study-SWOT-MOD View project**. [s.l.: s.n.]. Disponível em: <<https://www.researchgate.net/publication/236588657>>.
- VAN DEN DOOL, H. **Empirical Methods in Short-Term Climate Prediction**. [s.l.] Oxford University Press, 2006.
- VITART, F. et al. The subseasonal to seasonal (S2S) prediction project database. **Bulletin of the American Meteorological Society**, v. 98, n. 1, p. 163–173, 1 jan. 2017.
- VOLDOIRE, A. et al. SURFEX v8.0 interface with OASIS3-MCT to couple atmosphere with hydrology, ocean, waves and sea-ice models, from coastal to global scales. **Geoscientific Model Development**, v. 10, n. 11, p. 4207–4227, 20 nov. 2017.
- WALKER, G. T. Ceará (Brazil) famines and the general air movement. **Beitrag zur Physik der freien Atmosphäre**, v. 14, p. 88–93, 1928.
- WILLMOTT, C.; MATSUURA, K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. **Climate Research**, v. 30, p. 79–82, 2005.
- WMO. **WMO Statement on the State of the Global Climate in 2019**. [s.l.: s.n.]. v. WMO-No. 1248

WU, D.; JIANG, Z.; MA, T. Projection of summer precipitation over the Yangtze–Huaihe River basin using multimodel statistical downscaling based on canonical correlation analysis.

Journal of Meteorological Research, v. 30, n. 6, p. 867–880, 17 dez. 2016.

YNOUE, R. Y. et al. **Meteorologia: noções básicas**. [s.l: s.n.].