



DOI: 10.5380/abclima

AVALIAÇÃO DA PERFORMANCE DA PREVISÃO SAZONAL PARA O BRASIL UTILIZANDO O CFSv2 E ECMWF-SEAS5

*PERFORMANCE ASSESSMENT OF SEASONAL FORECASTING
FOR BRAZIL USING CFSv2 AND ECMWF-SEAS5*

*EVALUACIÓN DEL DESEMPEÑO DEL PRONÓSTICO ESTACIONAL
PARA BRASIL UTILIZANDO CFSv2 Y ECMWF-SEAS5*

Cassia Akemi Castro Kuki  

Universidade Federal de Itajubá
cassiakuki@unifei.edu.br

Glauber Willian de Souza Ferreira  

Universidade Federal de Itajubá
glauber_ferreira@unifei.edu.br

Michelle Simões Reboita  

Universidade Federal de Itajubá
reboita@unifei.edu.br

Resumo: Como a previsão climática sazonal é de grande importância para vários setores da sociedade (agricultura, geração de energia, turismo etc.), este estudo tem como objetivo apresentar a performance de dois modelos climáticos globais em prever o clima sazonal no Brasil. As previsões analisadas são provenientes de um modelo climático dos Estados Unidos (CFSv2) e de um modelo da Europa (ECMWF). Foram validadas as previsões de 15 trimestres (de AMJ de 2019 a JJA de 2020) mediante comparações com as análises de chuva do *Climate Prediction Center* (CPC). Os resultados indicam que, em geral, o modelo do ECMWF é mais úmido do que o CFSv2. Análises por subdomínios do Brasil mostram que na região Sul a performance dos dois modelos é similar, com Índice de Concordância de Willmott (d) igual a 0,57 (0,54) para ECMWF (CFSv2) e correlação de Pearson (r) igual a 0,6 para ambos os modelos. No Sudeste (Nordeste), a performance das previsões de precipitação do ECMWF é um pouco superior às do CFSv2, com d equivalente a 0,95 (0,97) e r igual a 0,97 (0,97). Por fim, na AMZ, a melhor previsão é obtida pelo CFSv2, com d correspondendo a 0,92 e r a 0,90.
Palavras-Chave: Precipitação. Prognóstico Sazonal. Validação. Modelos Globais. La Niña.

Abstract: Seasonal climate forecasting is important for various sectors of society (agriculture, power generation, tourism etc.). This study has as purpose to present the performance of two global climate models in predicting the seasonal climate in Brazil. The analyzed predictions are from North-American and European climate models (CFSv2 and ECMWF, respectively). The 15-quarter forecasts (from AMJ 2019 to JJA 2020) were validated through comparisons with the *Climate Prediction Center* (CPC) rain analysis. The results show that in general the ECMWF model is wetter than the CFSv2. Subdomains of Brazil analysis show that the performance of the two models in the South region is similar, with Index of Agreement (d) equal to 0.57 (0.54) for ECMWF (CFSv2) and Pearson correlation (r) equal to 0.6 for both models. In the Southeast (Northeast), the performance of ECMWF is slightly superior to those of CFSv2, with d equivalent to 0.95 (0.97) and r equal to 0.97 (0.97). Finally, in AMZ, the best prediction is obtained by CFSv2, with d corresponding to 0.92 and r equal to 0.90.

Keywords: Precipitation. Seasonal Forecast. Validation. Global Models. La Niña.

Resumen: Dado que la predicción climática estacional es de gran importancia para varios sectores de la sociedad (agricultura, generación de energía, turismo, etc.), este estudio tiene como objetivo presentar el desempeño de dos modelos climáticos globales en la predicción del clima estacional en Brasil. Los pronósticos analizados provienen de un modelo climático de Estados Unidos (CFSv2) y de un modelo de Europa (ECMWF). Los pronósticos de 15 trimestres (de AMJ 2019 a JJA 2020) se validaron mediante comparaciones con el análisis de lluvia del Centro de Predicción Climática (CPC). Los resultados indican que, en general, el modelo ECMWF es más húmedo que el CFSv2. Los análisis por subdominios de Brasil muestran que en la región Sur el desempeño de los dos modelos es similar, con el Índice de Concordancia Willmott (d) igual a 0.57 (0.54) para ECMWF (CFSv2) y la correlación de Pearson (r) igual a 0.6 para ambos modelos. En el Sureste (Noreste), el desempeño de los pronósticos de precipitación del ECMWF es levemente superior a los del CFSv2, con d equivalente a 0,95 (0,97) y r igual a 0,97 (0,97). Finalmente, en AMZ, la mejor predicción se obtiene mediante CFSv2, con d correspondiente a 0,92 y r a 0,90.

Palabras claves: Precipitación. Pronóstico estacional. Validación. Modelos globales. La Niña.

Submetido em: 12/10/2020

Aceito para publicação em: 01/10/2021

Publicado em: 13/11/2021



INTRODUÇÃO

A previsão de variáveis meteorológicas como precipitação e temperatura do ar, em diferentes escalas temporais, é de grande importância para a tomada de decisão e mitigação dos efeitos de sua variabilidade em diversos setores socioeconômicos. Essas previsões podem ser de curto, médio e longo prazos. Para o curto prazo, horizonte de até 10 dias, o termo utilizado é *previsão de tempo* (ROBERTSON et al., 2020). A *previsão climática subsazonal* corresponde àquela feita para um período entre dez dias e dois meses (VITART e ROBERTSON, 2018), enquanto a *previsão climática sazonal* refere-se à previsão que compreende o horizonte temporal de dois meses a um ano (DOBLAS-REYES et al., 2013; VITART e ROBERTSON, 2018). A longo prazo, as *previsões climáticas decadais* abrangem aquelas realizadas para o período de um a 30 anos (DOBLAS-REYES et al., 2013) e, por fim, as *projeções climáticas* estimam as possíveis evoluções do clima em escalas temporais maiores (BARRY e CHORLEY, 2010; DOBLAS-REYES et al., 2013; YNOUE et al., 2017). No entanto, salienta-se que as delimitações entre essas escalas temporais não são rígidas, visto que há sobreposições entre os diferentes horizontes de previsão decorrentes de processos físicos comuns às distintas faixas temporais de previsão climática (DOBLAS-REYES et al., 2013; MEEHL et al., 2021).

Nas previsões climáticas sazonais, foco do presente estudo, os modelos numéricos devem ser hábeis a simular as interações entre os componentes do sistema climático (atmosfera, hidrosfera, criosfera, litosfera e biosfera), de tal forma que o desempenho de suas previsões está associado à sua capacidade de predição dos modos de variabilidade atmosférica e oceânica (MEEHL et al., 2021). Esses modelos são inicializados a partir de um conjunto de dados composto por observações meteorológicas que indicam um estado atual da atmosfera. Contudo, apesar do conjunto global de obtenção de dados possuir um grande número de observações, esse sistema não possui medições *in situ* cobrindo toda a superfície do planeta. Além disso, os dados advindos de ar superior e por satélites podem conter erros sistemáticos e não necessariamente apresentam resoluções uniformes ou medições no mesmo horário. Por esses motivos, realiza-se a assimilação de dados, na qual um conjunto uniforme e consistente dessas observações é criado para ser fornecido aos modelos numéricos como condições iniciais para a realização das previsões (YNOUE et al., 2017; ROBERTSON e VITART, 2019).

No Brasil, a previsão climática sazonal é executada em modo operacional por poucos centros meteorológicos, tais como o Centro de Previsão de Tempo e Estudos Climáticos do Instituto Nacional de Pesquisas Espaciais (CPTEC/INPE; as previsões estão disponíveis no sítio eletrônico <http://ftp.cptec.inpe.br/clima/Modelos_Numericos/BAM1.2/>) e Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME; as previsões estão disponíveis no sítio eletrônico <http://www.funceme.br/dashboard/climate_forecast>). Além desses centros, instituições de ensino como a Universidade de São Paulo (USP) e Universidade Federal de Itajubá (UNIFEI) têm atuado juntas para realizar validações de previsões climáticas sazonais para o Brasil com o *Regional Climate Model* (RegCM), a fim de implementarem operacionalmente esse modelo (REBOITA et al., 2018).

Previsões climáticas sazonais robustas podem beneficiar tomadores de decisão de inúmeros setores socioeconômicos. As potencialidades da aplicabilidade das previsões se estendem para a agricultura, energia, transporte, saúde, turismo, entre outros setores.

A agricultura é uma das atividades mais sensíveis aos efeitos climáticos, dado que sua produtividade depende diretamente das condições de temperatura e precipitação da região em que é realizada (PIEDRA-BONILLA et al., 2020). A precipitação exerce papel essencial em etapas importantes da atividade agrícola como a preparação do solo, plantio, aplicação de pesticidas e colheita (MORETO et al., 2020). Neste contexto, Cardoso et al. (2010) verificaram que previsões estendidas (de até 15 dias) de precipitação geraram estimativas de produtividade agrícola mais confiáveis durante o período de crescimento da cultura, se comparadas às estimativas geradas somente com dados climatológicos. Diversos outros estudos avaliaram a utilidade de previsões climáticas sazonais em modelos de produtividade agrícola, a fim de uma maior antecipação e previsibilidade das safras (OETTLI et al., 2011; ZINYENGERE et al., 2011; MALHERBE et al., 2014; BUSSAY et al., 2015; CHIPANSHI et al., 2015; DARANI et al., 2015; DUMONT et al., 2015; CAPA-MOROCHO et al., 2016).

Informações climáticas são importantes não apenas para prever os rendimentos de colheita, mas também para determinar os períodos ótimos de plantio, avaliar a viabilidade econômica de diferentes práticas de gerenciamento agrícola e orientar decisões que favoreçam o aumento de rendimentos (MARTINS et al., 2018). No Brasil, as previsões climáticas sazonais são ferramentas valiosas, visto o papel fundamental da atividade agrícola na economia, representando 21,4% do Produto Interno Bruto (PIB) do país, bem como sua importância nos mercados globais (MARTINS et al., 2018; CEPEA/USP-CNA, 2020).

Martins et al. (2018) investigaram a eficácia da utilização de previsões climáticas sazonais de precipitação oriundas do modelo climático Eta acopladas ao modelo de simulação de culturas agrícolas AquaCrop para prever a produtividade da cultura do milho na região do Semiárido nordestino. Os resultados mostraram que o modelo alimentado com previsões climáticas sazonais apresentou ótimo desempenho na previsão da produtividade do milho com, pelo menos, 30 dias de antecedência à colheita. Para o setor do leste do Semiárido nordestino, o modelo apresentou menores incertezas nas previsões realizadas com antecedência inferior a 60 dias. Os autores sugerem que as melhores previsões dessa área estão relacionadas ao padrão de precipitação da região. Como os eventos de precipitação são mais frequentes no decorrer da estação chuvosa, eles são mais facilmente capturados pelos membros do modelo Eta, favorecendo um suprimento constante de água durante o ciclo de simulação de crescimento e desenvolvimento do milho (MARTINS et al., 2018).

Para o gerenciamento de recursos hídricos, Collischonn et al. (2005) utilizaram o modelo climático global do CPTEC integrado ao modelo hidrológico MGB-IPH para prever vazões futuras na bacia do rio Uruguai. Apesar do modelo climático subestimar a chuva na bacia, ao corrigir suas previsões mediante um método estatístico baseado na transformação da curva de distribuição de probabilidade de precipitação, os resultados de previsão de afluência representaram as vazões observadas com melhor qualidade e desempenho do que as previsões obtidas a partir de modelos estatísticos baseados em médias e medianas mensais.

Ademais, no setor energético as informações relacionadas às previsões de vazões auxiliam na operação do Sistema Interligado Nacional (SIN), isto é, na otimização do despacho de usinas hidrelétricas em conjunto com o de usinas termelétricas. No caso do SIN, cuja matriz é predominantemente hidráulica, há uma forte dependência das vazões, que são suscetíveis à variabilidade da precipitação (CASTANHARO et al., 2007; FIGUEIREDO et al., 2007; PONTES et al., 2013; FAN et al., 2014; DIAS et al., 2017).

Considerando a bacia do rio Grande, no trecho a montante da usina hidrelétrica de Furnas, Cossich et al. (2015) criaram cenários de afluências com os modelos numéricos ECHAM4.5, CFS, COLA/IRI e CCM3 associados a modelos autorregressivos multivariados (ARx), que consideram informações de vazões passadas e precipitação. Esses cenários de vazão foram gerados para situações de afluências máxima, mínima e média para um, dois e três meses à frente. Ao compararem os resultados das afluências geradas a partir do modelo ARx

com aqueles obtidos a partir de modelos autorregressivos simples (AR), que consideram apenas a vazão passada, os autores observaram que a metodologia multivariada foi capaz de capturar com maior sensibilidade a variabilidade natural das vazões sazonais em relação à metodologia simples, aprimorando a processo de geração de cenários de afluências.

De Paiva et al. (2020) também avaliaram cenários de afluências gerados pelo modelo climático CFSv2 integrado ao modelo hidrológico *Soil Moisture Accounting Procedure* (SMAP) e ao modelo de Redes Neurais Artificiais (RNA) na previsão de vazões futuras para a usina hidrelétrica de Três Marias, na bacia do São Francisco. Esses cenários foram construídos a partir de situações de vazão máxima e mínima para os modelos SMAP e RNA para um, dois e três meses à frente. Ao compararem os resultados simulados a partir desses modelos de chuva-vazão com aqueles encontrados pelo modelo GEVAZP (modelo computacional baseado na geração de séries sintéticas a partir da modelagem autorregressiva), De Paiva et al. (2020) observaram que a inserção de informações de precipitação permite reduzir a amplitude de cenários gerados pelo GEVAZP, excluindo aqueles com pouca ou nenhuma probabilidade de ocorrência e, conseqüentemente, melhorando a otimização do planejamento da operação de reservatórios no SIN.

Diante da importância de previsões climáticas sazonais mais precisas e de sua vasta aplicação em diferentes setores da sociedade, esse estudo tem como objetivo validar as previsões climáticas sazonais dos modelos climáticos globais CFSv2 e ECMWF para o Brasil.

MATERIAL E MÉTODOS

Modelos Numéricos

CFSv2

O *Climate Forecast System version 2* (CFSv2) foi desenvolvido pelo *National Centers for Environmental Prediction* (NCEP), do *National Oceanic and Atmospheric Administration* (NOAA). O CFSv2 é uma versão aprimorada do modelo CFSv1 em aspectos relacionados à assimilação de dados e aos componentes do modelo de previsão, entrando em operação em março de 2011 (SAHA et al., 2014).

Trata-se de um modelo climático acoplado que representa a interação entre os componentes do sistema climático, contando com diferentes tipos de dados. O CFSv2 é



constituído pelo modelo atmosférico *Global Forecast System* (GFS), com resolução T126 (mas disponibilizado ao público com resolução de ~ 100 km ou $\sim 0,937^\circ$) e 64 níveis verticais. Seu modelo oceânico é o *Geophysical Fluid Dynamics Laboratory Modular Ocean Model version 4* (GFDL MOM4), com resolução de $0,25^\circ$ na região equatorial e $0,5^\circ$ a partir dos trópicos e 40 níveis verticais, além do modelo interativo GFDL *Sea Ice Simulator* com três camadas de gelo marinho (duas de gelo e uma de neve). O CFSv2 também utiliza o modelo de superfície terrestre de NOAA de quatro camadas (SAHA et al., 2010; 2014).

As previsões do CFSv2 são inicializadas quatro vezes ao dia (00, 06, 12 e 18 UTC) a partir das condições iniciais disponibilizadas pelo *Climate Data Assimilation System version 2* (CDAS). Em cada inicialização, há mais quatro simulações que possuem diferentes horizontes temporais. Na primeira rodada de cada horário sinótico, o horizonte de previsão é de nove meses e as condições iniciais não sofrem perturbações. De outra forma, as execuções adicionais são perturbadas e, no horário das 00 UTC, as rodadas têm extensão de três meses, enquanto nos horários das 06, 12 e 18 UTC, a extensão é de 45 dias (SAHA et al., 2010; 2014).

As previsões estão disponibilizadas no sítio eletrônico <<https://nomads.ncep.noaa.gov/pub/data/nccf/com/cfs/prod/>>, porém os dados apresentam rotatividade de sete dias. Neste estudo, foram utilizadas as previsões de março de 2019 até maio de 2020.

ECMWF-SEAS5

O *European Centre for Medium-Range Weather Forecasts* (ECMWF) fornece previsões climáticas sazonais para todo o globo desde 1997, tendo seu sistema de previsão sazonal atualizado a cada 5 anos, aproximadamente (JOHNSON et al., 2019). O System 5 (SEAS5) é a quinta geração de sistema de previsão sazonal do ECMWF, entrando em operação em 2017 e substituindo seu predecessor, o System 4 (SEAS4) (ECMWF, 2017; JOHNSON et al., 2019). O SEAS5 possui aprimoramentos em seus componentes do modelo e condições iniciais, bem como melhorias em seu módulo atmosférico (*Integrated Forecast System* – IFS), especialmente na representação da convecção tropical e no aumento da resolução horizontal, com aproximadamente 35 km^2 (BECHTOLD et al., 2014; ECMWF, 2017; JOHNSON et al., 2019; GUBLER et al., 2020). O módulo oceânico do SEAS5 também teve melhorias em sua

representação física e resoluções horizontal e vertical (MADEC, 2016; ECMWF, 2017; JOHNSON et al., 2019).

As previsões são executadas uma vez ao mês, inicializadas sempre no primeiro dia de cada mês, com horizonte temporal de 215 dias (≈ 7 meses) e contando com *ensemble* composto por 51 membros, isto é, 51 previsões em que há uma combinação de perturbações nas condições atmosféricas iniciais, na temperatura da superfície do mar (TSM) e na ativação da física estocástica (JOHNSON et al., 2019). As condições atmosféricas iniciais do SEAS5 são fornecidas pelas análises operacionais do ECMWF. O membro 0 do *ensemble* é inicializado a partir de condições atmosféricas iniciais não perturbadas. As condições iniciais para todos os outros membros do *ensemble* possuem perturbações aplicadas a alguns campos para representar a incerteza do estado inicial da atmosfera. Os campos perturbados incluem todas as camadas superiores de ar e um conjunto limitado de campos de umidade do solo, temperatura do solo, neve, temperatura do gelo marinho e temperatura superficial (ECMWF, 2017; JOHNSON et al., 2019).

Os dados de superfície do SEAS5 (*Seasonal forecast daily data on single levels*), incluindo total de precipitação (calculado a cada 24 horas desde o início da previsão), são fornecidos com resolução horizontal de 1° e são disponibilizados no sítio <<https://cds.climate.copernicus.eu/cdsapp#!/dataset/seasonal-original-single-levels?tab=form>>. Neste trabalho, os conjuntos de dados selecionados incluem previsões de março de 2019 a maio de 2020.

Dados Observados

Torres et al. (2020), ao validarem diferentes bases de dados de precipitação para as bacias hidrográficas dos rios São Francisco e Sapucaí, observaram que o produto da análise do *Climate Prediction Center* (CPC) apresentou resultados satisfatórios na representação espacial da precipitação medida *in situ*, podendo ser utilizado com confiabilidade na validação de previsões.

A análise CPC *Gauge-Based Analysis of Global Daily Precipitation* (CPC-Global) é um produto disponibilizado pelo *National Oceanic and Atmospheric Administration/Climate Prediction Center* (NOAA/CPC). É um produto com robustez qualitativa e quantitativa devido à combinação dos dados de precipitação diária oriundos de medidas em superfície e à



utilização de diversas técnicas de interpolação (CHEN et al., 2008; SUN et al., 2018). As informações de precipitação são disponibilizadas diariamente no sítio eletrônico <https://ftp.cpc.ncep.noaa.gov/precip/CPC_UNI_PRCP/GAUGE_GLB/>. Para este estudo, foram utilizados dados diários com resolução espacial de 0,5°, do período de abril de 2019 a agosto de 2020.

O Quadro 1 apresenta uma síntese das informações dos modelos climáticos e da análise de precipitação utilizados neste estudo.

Quadro 1 – Conjunto de informações dos modelos climáticos e dados de análise de precipitação utilizados.

| Dado | Resolução horizontal | Período | Link | Referência |
|-------|----------------------|----------------------------|---|---|
| CPC | 0,5° | abril/2019- agosto/2020 | https://ftp.cpc.ncep.noaa.gov/precip/CPC_UNI_PRCP/GAUGE_GLB/ | Chen et al. (2008) Sin et al. (2018) |
| CFSv2 | ~0,937° | março/2019- maio/2020 | https://nomads.ncep.noaa.gov/pub/data/nccf/com/cfs/prod/ | Saha et al. (2010; 2014) |
| ECMWF | ~1,0° | março/2019- maio/2020 | https://cds.climate.copernicus.eu/cdsapp#!/dataset/seasonal-original-single-levels?tab=form | ECMWF (2017) Johnson et al. (2019) |

Fonte: Elaborado pelos autores (2020).

Métodos

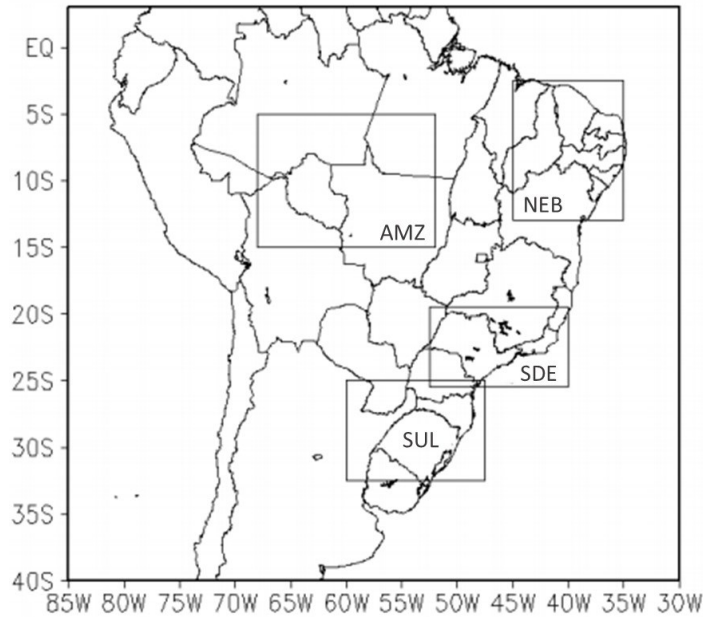
Para a comparação das previsões sazonais do CFSv2 e do ECMWF com os dados observados do CPC, foi necessário seguir as etapas abaixo descritas.

Construção dos ensembles

Como a modelagem numérica do clima conta com diversas fontes de incertezas, tais como erros nas condições iniciais disponibilizadas aos modelos climáticos e aproximações nas equações que descrevem o comportamento atmosférico e ao próprio caos da atmosfera, é importante a aplicação de técnicas para a minimização dessas incertezas. Para isso, utiliza-se a técnica de *ensemble*, que é a média das simulações obtidas a partir de modificações nas condições iniciais para um determinado período (YNOUE et al., 2017; ROBERTSON e VITART, 2019).

Neste estudo, foi utilizada a técnica de *ensemble* nas previsões executadas pelo CFSv2 e ECMWF, cujo cálculo é apresentado no Quadro 2. Para o CFSv2, se o trimestre a ser validado é, por exemplo, abril, maio e junho (AMJ) de 2019, utilizam-se as previsões inicializadas nos dias 01, 05, 10, 15, 20 e 25 (que são chamadas de membros) do mês anterior ao do período desejado (março de 2019) para o cálculo do *ensemble*. O mês de inicialização das previsões é descartado das análises por ser o período de *spin-up time* (GIORGI e MEARNNS, 1999; DIRMEYER et al., 2003; 2009; LI et al., 2009). No caso do ECMWF, as previsões são geradas sempre no primeiro dia do mês e há 51 membros. Esses 51 membros são utilizados no *ensemble*. Como para o CFSv2, se o trimestre de interesse é AMJ, são selecionadas as previsões iniciadas em março e o primeiro mês é descartado das análises. Como relatado, foram utilizadas previsões climáticas sazonais do CFSv2 e ECMWF inicializadas nos meses de março de 2019 a maio de 2020. Dado que o primeiro mês de previsão é descartado das análises, utilizaram-se previsões trimestrais médias obtidas a partir do segundo mês prognóstico. Assim, foram consideradas previsões dos trimestres de Abril-Maio-Junho (AMJ) de 2019 (fornecida pela previsão climática sazonal inicializada em março de 2019) a Junho-Julho-Agosto (JJA) de 2020 (obtida pela previsão climática sazonal inicializada em maio de 2020). Com base nessa metodologia, o presente estudo calculou a média de precipitação prevista de 15 trimestres, para o domínio que inclui a América do Sul e oceanos adjacentes, como ilustra a Figura 1.

Figura 1 – Domínio e subdomínios da América do Sul em estudo: Sudeste (SDE), Sul (SUL), Nordeste (NEB) e Amazônia (AMZ).



Fonte: Elaborado pelos autores (2020).

Quadro 2 – Esquema da técnica de *ensemble* utilizada neste trabalho. O exemplo se trata da previsão para o trimestre AMJ, sendo os modelos inicializados no mês de março.

| Previsão | Mês de início da simulação | Dias de inicialização | Média trimestral | Cálculo do <i>ensemble</i> |
|----------|----------------------------|-----------------------|---|--|
| CFSv2 | março | 1 | $\text{med1} = \frac{\text{abr} + \text{mai} + \text{jun}}{3}$ | $\text{EnsembleAMJ} = (\text{med1} + \text{med5} + \text{med10} + \text{med15} + \text{med20} + \text{med25})/6$ |
| | | 5 | $\text{med5} = \frac{\text{abr} + \text{mai} + \text{jun}}{3}$ | |
| | | 10 | $\text{med10} = \frac{\text{abr} + \text{mai} + \text{jun}}{3}$ | |
| | | 15 | $\text{med15} = \frac{\text{abr} + \text{mai} + \text{jun}}{3}$ | |
| | | 20 | $\text{med20} = \frac{\text{abr} + \text{mai} + \text{jun}}{3}$ | |
| | | 25 | $\text{med25} = \frac{\text{abr} + \text{mai} + \text{jun}}{3}$ | |
| ECMWF | março | 1 | $\text{MédiaA} = \frac{\sum_{i=1}^{51} x_i}{51}$ | $\text{EnsembleAMJ} = (\text{medA} + \text{medM} + \text{medJ})/3$ |
| | | | $\text{MédiaM} = \frac{\sum_{i=1}^{51} x_i}{51}$ | |
| | | | $\text{MédiaJ} = \frac{\sum_{i=1}^{51} x_i}{51}$ | |

Fonte: Elaborado pelos autores (2020).

Validação das previsões

Para validar as previsões de precipitação do CFSv2 e ECMWF, foi realizada a comparação com os dados da análise do CPC. Porém, como esses modelos climáticos apresentam resoluções distintas, foi necessária a interpolação dos dados do CPC para a resolução do CFSv2 e ECMWF, utilizando-se o método bilinear (PRESS et al., 2007). Com essas simulações e observações, construíram-se os mapas de precipitação simulada e observada, bem como os de viés (Quadro 1).

Além da avaliação de distribuição espacial da precipitação, computaram-se também as médias trimestrais para quatro subdomínios brasileiros apresentados na Figura 1, a saber: Sudeste (SDE), Sul (SUL), Nordeste (NEB) e Amazônia (AMZ). A partir das médias regionais, foram calculadas diferentes métricas estatísticas, como mostra o Quadro 3.

Quadro 3 – Métricas estatísticas para comparação entre precipitação simulada pelo CFSv2 e ECMWF e observada pela análise CPC.

| Estatística | Equação | Descrição |
|--|---|---|
| Viés | $viés = \hat{y}_t - y_t$ <p>onde:</p> <p>\hat{y}: Precipitação trimestral prevista pelo CFSv2 ou ECMWF</p> <p>y: Precipitação trimestral observada pela análise do CPC</p> <p>t: Período</p> | Estima a correspondência entre os valores previsto e observado de precipitação. Para esse critério, quando o viés é próximo de zero, a variável está sendo bem observada (previsão se aproxima do valor observado ou real), viés negativo indica que a previsão subestima a variável, e o viés positivo indica superestimação (WILKS, 2011). |
| Coefficiente de determinação (R^2) | $R^2 = 1 - \frac{\sum_{t=1}^N (y_t - \hat{y}_t)^2}{\sum_{t=1}^N (y_t - \bar{y})^2}$ <p>onde:</p> <p>\hat{y}: Precipitação trimestral prevista pelo CFSv2 ou ECMWF</p> <p>y: Precipitação trimestral observada pela análise do CPC</p> <p>\bar{y}: Média da precipitação trimestral observada pela análise do CPC para todo o horizonte de análise</p> <p>t: Período</p> <p>N: Número de amostras</p> | Avalia o ajuste das previsões em relação às observações, de tal forma que a variação dos dados simulados pode ser explicada pela variação dos dados observados. Nesse critério, R^2 próximo a zero indica que a variável prevista não está bem ajustada, enquanto R^2 próximo a 1 indica bom ajuste da previsão (WILKS, 2011; MONTGOMERY et al., 2015). |
| Índice de concordância de Willmott (d) | $d = 1 - \frac{\sum_{t=1}^N (\hat{y}_t - y_t)^2}{\sum_{t=1}^N (\hat{y}_t - \bar{y} + y_t - \bar{y})^2}$ <p>onde:</p> | Descreve a precisão das previsões de uma determinada variável em relação às observações, podendo |

| | |
|---|---|
| <p>\hat{y}_t: Precipitação trimestral prevista pelo CFSv2 ou ECMWF</p> <p>y_t: Precipitação trimestral observada pela análise do CPC</p> <p>\bar{y}: Média da precipitação trimestral observada pela análise do CPC para todo o horizonte de análise</p> <p>t: Período</p> <p>N: Número de amostras</p> | <p>variar entre 0 e 1. Quando d é próximo de 0, os valores previstos e observados discordam entre si, enquanto d próximo de 1 indica melhor ajuste das previsões (WILLMOTT, 1981)</p> |
| <p>Correlação de Pearson (r)</p> $r = \frac{\sum_{t=1}^N (y_t - \bar{y})(\hat{y}_t - \bar{\hat{y}})}{\sqrt{\sum_{t=1}^N (y_t - \bar{y})^2} \sqrt{\sum_{t=1}^N (\hat{y}_t - \bar{\hat{y}})^2}}$ <p>onde:</p> <p>\hat{y}_t: Precipitação trimestral prevista pelo CFSv2 ou ECMWF</p> <p>y_t: Precipitação trimestral observada pela análise do CPC</p> <p>$\bar{\hat{y}}$: Média da precipitação trimestral prevista pelo CFSv2 ou ECMWF para todo o horizonte de análise</p> <p>\bar{y}: Média da precipitação trimestral observada pela análise do CPC para todo o horizonte de análise</p> <p>t: Período</p> <p>N: Número de amostras</p> | <p>Mede o grau de correlação entre as variáveis prevista e observada, podendo variar entre -1 e 1. Nesse critério, $r=1$ indica correlação perfeita e positiva, de modo que os valores da variável analisada são diretamente proporcionais; $r=-1$ indica correlação perfeita e negativa, sendo os valores inversamente proporcionais; e $r=0$ indica que não há correlação entre os valores (WILKS, 2011; MONTGOMERY et al., 2015). De acordo com Alencar e Schmitz (2012), os intervalos podem ser interpretados da seguinte forma: $r=1$ (-1) indica correlação positiva (negativa) perfeita; 0,7 a 0,99 (-0,7 a -0,99) indica correlação positiva (negativa) forte; 0,3 a 0,7 (-0,3 a -0,7) representa correlação positiva (negativa) moderada; 0 a 0,3 (0 a -0,3) sugere correlação positiva (negativa) fraca; e $r=0$ indica correlação inexistente.</p> |

Fonte: Elaborado pelos autores (2020).

RESULTADOS E DISCUSSÃO

Padrão Espacial

Para a análise dos resultados, foram considerados todos os trimestres apresentados no Quadro 2, porém, por brevidade, a Figura 2 apresenta apenas os trimestres referentes às estações de JJA/2019, SON/2019, DJF/2019/2020, MAM/2020 e JJA/2020.

Os trimestres JJA/2019 e JJA/2020 (Figura 2a,e) correspondem ao inverno austral, que é caracterizado por ser estação seca nas regiões Sudeste e Centro-Oeste e em porções do nordeste e norte do Brasil (REBOITA et al., 2010; 2018). As previsões de ambos os modelos climáticos (CFSv2 e ECMWF) conseguem reproduzir o padrão espacial da precipitação com

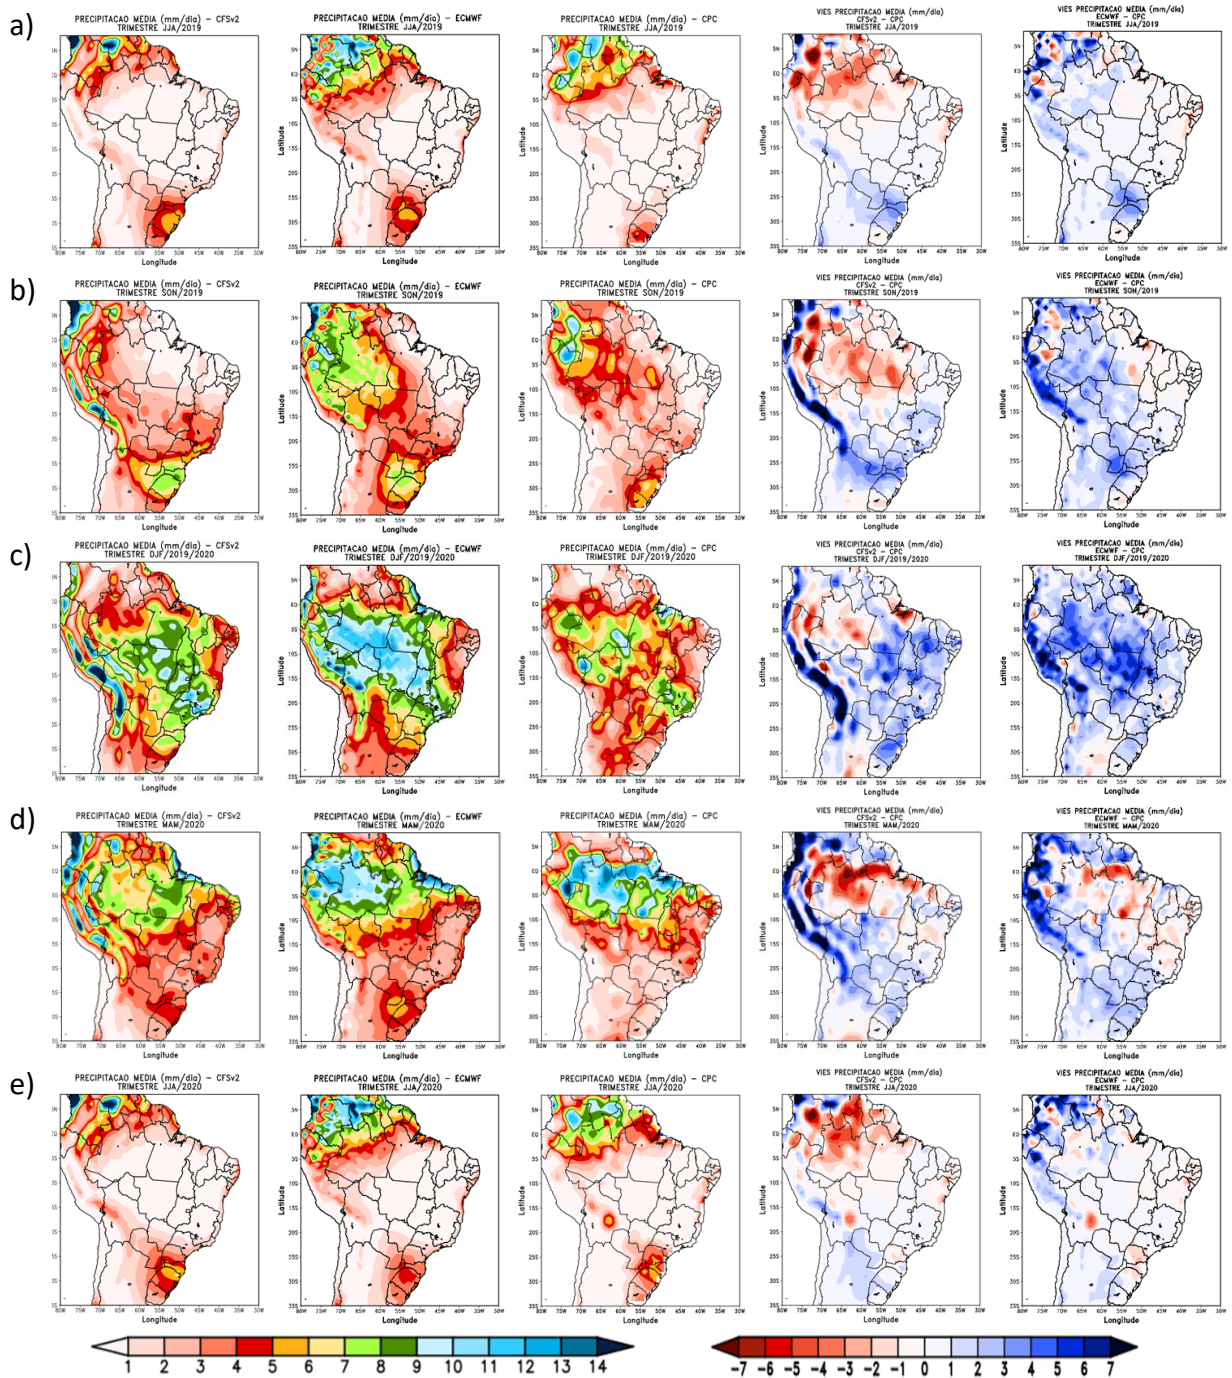
boa representatividade dos valores na região do Brasil central. No setor sul do Brasil, ambos os modelos simulam condições mais úmidas (vieses de 1,561 e 1,389 mm/dia para CFSv2 e ECMWF, respectivamente), enquanto no noroeste do Brasil, o ECMWF indica viés úmido e o CFSv2 evidencia viés seco (vieses de 1,075 e -0,400 mm/dia para ECMWF e CFSv2, respectivamente). Resultados semelhantes para o CFSv2 nos meses de inverno foram obtidos por Silva et al. (2014) e Reboita et al. (2018). Silva et al. (2014) avaliaram as previsões sazonais retrospectivas (*hindcasts*) do CFSv2 de 1983 a 2010 e observaram que o modelo apresentou subestimativa de precipitação sobre o noroeste brasileiro e superestimativa em porções do sul do país. Reboita et al. (2018) examinaram as previsões de JJA de 2013 e encontraram viés seco do CFSv2 sobre o noroeste do Brasil. Os autores também verificaram que ao aninhar o modelo global CFSv2 ao modelo regional RegCM, o sinal do viés era invertido, indicando simulação de condições mais úmidas sobre quase todo o país.

O trimestre SON/2019 (Figura 2b) refere-se à primavera austral, representando a transição entre os períodos seco e úmido em grande parte do país (em grande parte da América do Sul, o período seco se estende de maio a setembro e o período úmido de novembro a março; WANG et al., 2012). Com o início do período chuvoso da monção sul-americana (REBOITA et al., 2010; MARENGO et al., 2012; ASHFAQ et al., 2020), os modelos CFSv2 e ECMWF simulam aumento dos volumes de precipitação em relação ao inverno para todo o país, em especial para as regiões Sudeste, Centro-Oeste e Nordeste. Na região sul do Brasil, as simulações indicam condições mais úmidas que aquelas observadas, enquanto para a região Norte os modelos discordam, uma vez que o CFSv2 simula condições mais secas e o ECMWF mais úmidas. Os resultados do CFSv2 corroboram aqueles encontrados por Reboita et al. (2018), que identificaram viés seco do modelo global sobre o noroeste do Brasil, bem como viés úmido nas demais regiões do país, considerando-se o trimestre SON de 2013.

O trimestre DJF/2019/2020 (Figura 2c) corresponde ao verão austral, marcado pelo período chuvoso em grande parte do país, com a presença de uma banda de precipitação que se estende do sul da Amazônia, passando pelo sudeste do Brasil e alcançando o oceano Atlântico. Essa banda é denominada Zona de Convergência do Atlântico Sul (ZCAS; DE QUADRO et al., 2016; SILVA et al., 2019). Apesar dos modelos globais terem simulado um aumento da precipitação em praticamente todo o país em relação à estação anterior, ambas as previsões superestimaram a precipitação nesse trimestre, embora o CFSv2 tenha mostrado condições mais secas sobre o estado do Amazonas. De forma similar, Silva et al. (2014)

verificaram que o CFSv2 indicou viés mais seco na região amazônica e condições mais úmidas no restante do país durante os meses de verão.

Figura 2 - Precipitação trimestral média (mm/dia). CFSv2 (primeira coluna), ECMWF (segunda coluna), CPC (terceira coluna), viés CFSv2-CPC (quarta coluna), viés ECMWF-CPC (quinta coluna): a) JJA de 2019, b) SON de 2019, c) DJF de 2019/2020, d) MAM de 2020, e e) JJA de 2020.



O trimestre MAM/2020 (Figura 2d) compreende o outono austral, representando a transição entre o período úmido e seco em grande parte do país. Nesse período, há uma redução das condições de precipitação nas regiões Sudeste, Centro-Oeste e Sul do Brasil. Os modelos simulam essa redução em relação ao verão nessas regiões, porém apresentam um viés úmido. Por outro lado, nas regiões Nordeste e Norte, há a mudança no sinal do viés, indicando condições mais secas. Resultados similares foram obtidos por Reboita et al. (2018) que encontraram viés seco do CFSv2 sobre a região Norte, bem como condições mais úmidas em setores do Nordeste, Centro-Oeste, Sudeste e Sul. Apesar dos vieses, os autores concluíram que o modelo global apresentou os melhores resultados de previsão de precipitação para o trimestre MAM de 2013 (seguido do CFSv2 aninhado ao modelo regional RegCM).

No período de validação dos modelos, predominaram condições de neutralidade no Pacífico tropical, sendo o registro de La Niña observado apenas a partir do trimestre JAS/2020 (CPC, 2021; WMO, 2021), que já não faz parte do período analisado no presente estudo. Nos resultados mostrados no trimestre JJA/2020, os modelos superestimaram a precipitação entre o Paraguai e o setor oeste do RS, o que indica que eles ainda não tinham sensibilidade ao resfriamento lento das águas do Pacífico, uma vez que essas anomalias implicam em déficit de precipitação na região mencionada (REBOITA et al., 2021). Entretanto, é válido mencionar que alguns estudos mostram que os impactos da La Niña sobre a precipitação na América do Sul podem ser observados mesmo em meses anteriores ao início do evento devido aos efeitos de teleconexão. Rodrigues e McPhaden (2014) relatam que o resfriamento no Pacífico central (conhecido como La Niña Modoki) está associado a um aquecimento do Atlântico tropical norte e resfriamento do Atlântico tropical sul, o que induz a uma migração para norte da Zona de Convergência Intertropical (ZCIT) e consequente redução de precipitação no nordeste do Brasil. Tedeschi et al. (2013) e Wiedermann et al. (2021) destacam que o resfriamento da TSM nos setores central e leste do Pacífico equatorial (o que indica um evento La Niña com características dos tipos Canônico e Modoki) também está relacionado à redução de chuva no Nordeste e aumento de precipitação no Norte durante o trimestre de MAM, associado ao deslocamento da ZCIT. Essa condição é ilustrada na Figura 2d, com os maiores totais de precipitação no Norte e sua melhor representação pelo modelo ECMWF.

Andreoli et al. (2018) sugerem que no trimestre de JJA do ano de ocorrência do evento, há um aumento de anomalias negativas de precipitação ao norte de 10° S decorrentes da



célula de Walker anormalmente fraca, bem como pequenas áreas de anomalias positivas no sul do Brasil. Observa-se esse padrão na Figura 2e, a qual indica uma redução expressiva de chuva na maior parte do país e uma pequena região de maiores totais no sul do Brasil, condição melhor capturada pelo modelo CFSv2.

Considerando o extremo sul do Brasil, Grimm et al. (1998; 2000) concluem que as anomalias de chuva tendem a ser positivas no ano anterior à La Niña até a metade do ano de ocorrência do evento, característica presente na Figura 2b que apresenta maiores valores de precipitação no Rio Grande do Sul. As anomalias de precipitação associadas a eventos de La Niña podem ser causadas por diferentes fatores como mudanças na disponibilidade de umidade, na dinâmica de movimentos verticais, na estabilidade do ar, bem como uma combinação de todos esses aspectos (GRIMM et al., 2000).

É válido notar que os impactos decorrentes do evento La Niña sobre a precipitação em diferentes regiões do Brasil são simulados distintamente pelos dois modelos climáticos. No trimestre de MAM e JJA de 2020 (Figuras 2d,e), os maiores valores de precipitação no norte do Brasil associados à chegada da La Niña (ROGERS, 1988; TEDESCHI et al., 2013; ANDREOLI et al., 2018; WIEDERMANN et al., 2021) são melhor simulados pelo modelo ECMWF, enquanto os maiores volumes de chuva no Sul (GRIMM et al., 1998, 2000) são melhor capturados pelo modelo CFSv2. Algumas possíveis razões para isso relacionam-se a aprimoramentos no modelo climático do ECMWF, como a melhora da representação da convecção tropical no módulo atmosférico IFS e a maior habilidade de previsão de TSM dos oceanos Atlântico equatorial e Pacífico central e leste (MOLTENI et al., 2011; BARNSTON et al., 2012), conferindo ao modelo europeu melhor capacidade preditiva de precipitação nos trópicos. Além disso, Silva et al. (2014) avaliaram 28 anos de *hindcasts* do CFSv2 e identificaram erros sistemáticos de subestimativa de precipitação sobre o noroeste da América do Sul no trimestre de JJA.

Considerando outros modelos climáticos, estudos como os de Taschetto et al. (2014) e Tedeschi e Collins (2016) examinaram como 34 modelos do *Coupled Model Intercomparison Project Phase 5* (CMIP5) representam os diferentes tipos de El Niño e La Niña e seus efeitos sobre a precipitação na América do Sul. Taschetto et al. (2014) verificaram que, embora quase todos os modelos tenham sido hábeis em capturar a diferença entre os dois tipos de El Niño (Canônico e Modoki), a maioria deles falhou em reproduzir a assimetria entre os dois tipos de La Niña, apresentando eventos de La Niña no leste do Pacífico mais intensos que aqueles no Pacífico central, quando o oposto ocorreu nas observações. Para o trimestre de MAM,

Tedeschi e Collins (2016) concluíram que somente metade dos modelos reproduziu o sinal de precipitação na América do Sul associado ao evento La Niña Modoki e somente nove modelos reproduziram a chuva associada ao evento La Niña sobre a região centro-leste do Brasil (região de atuação da ZCAS). Essa característica é evidente na Figura 2d, a qual mostra que ambos os modelos climáticos superestimaram a precipitação no sudeste e sul do Brasil. A complexidade da simulação dos impactos de diferentes tipos de El Niño e La Niña sobre a chuva na América do Sul não decorre somente da dificuldade inerente aos modelos acoplados em representar os diferentes tipos de eventos, mas também da própria limitação dos modelos em prever os efeitos de teleconexão, dado que erros persistem mesmo quando os vieses na TSM são eliminados das simulações (TEDESCHI e COLLINS, 2016).

Avaliar detalhadamente as causas físicas das diferenças entre os dois modelos climáticos exige um conjunto maior de previsões em tempo real, bem como as previsões retrospectivas (*hindcasts*) de ambos os modelos. Assim, é possível identificar minuciosamente os erros sistemáticos dos dois modelos, o que permite uma interpretação física mais apropriada dos diferentes resultados. Ademais, estudos mostram que a representação dos diferentes tipos de El Niño e La Niña nos modelos climáticos é sensível à resposta atmosférica, particularmente na localização da convecção (KUG e HAM, 2011; HAM e KUG, 2012; KUG et al., 2012; XU et al., 2012), à habilidade de representação dos efeitos de teleconexões no oceano Índico (OKUMURA e DESER, 2010; SANTOSO et al., 2012; DU et al., 2013; WANG 2019; DE SOUZA et al., 2021), assim como aos diferentes esquemas de parametrização de convecção utilizados nos modelos (BELLENGER et al., 2013). Dado que o ECMWF e o CFSv2 utilizam parametrizações de convecção distintas, tal aspecto pode justificar parcialmente as diferenças nos resultados entre os modelos nos trimestres de MAM e JJA de 2020.

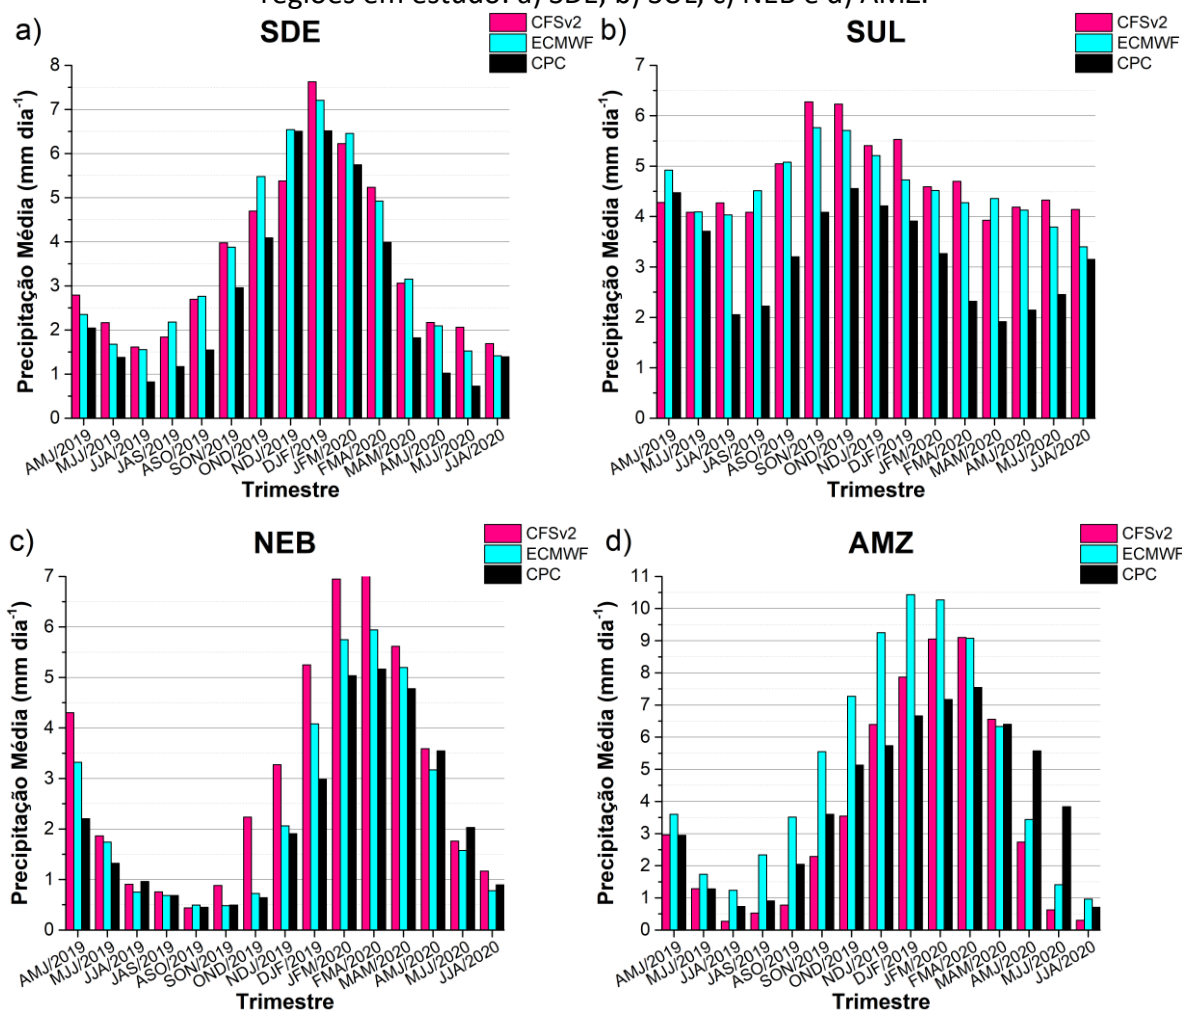
Em resumo, os trimestres analisados indicam que o ECMWF apresenta viés úmido, exceto na região Nordeste e norte do Sudeste, enquanto o CFSv2 evidencia viés seco na região Norte e úmido no Sul e porções do Centro-Oeste e Sudeste. Para uma análise mais detalhada, a próxima seção mostra as estatísticas calculadas para as regiões apresentadas na Figura 1 e para todos os trimestres considerados.

Validação por Região

Para uma melhor avaliação das previsões, foram calculadas as estatísticas de viés da precipitação trimestral, coeficiente de determinação (R^2), índice de concordância de Willmott (d) e coeficiente de correlação de Pearson (r) (Quadro 3) para os subdomínios brasileiros apresentados na Figura 1. Na Figura 3, são mostradas as médias trimestrais de precipitação prevista (CFSv2 e ECMWF) e observada (CPC).

O SDE (Figura 3a) apresenta ciclo anual de precipitação com variabilidade sazonal, típico de região influenciada pelo regime de monção, isto é, com verão marcado por maiores valores pluviométricos e por menores valores no inverno (REBOITA et al., 2010, 2012; SILVA e REBOITA, 2013; LLOPART et al., 2018; LEMES e REBOITA, 2019; MARRAFON e REBOITA, 2020). Ambos os modelos globais reproduzem o ciclo anual de precipitação, apesar da superestimativa dessa variável ao longo do período de análise (Tabela 1). Além disso, observa-se também que ambos os modelos conseguem reproduzir com qualidade o comportamento da chuva, uma vez que o R^2 indica o ajuste das previsões e seu valor é superior a 0,9; a concordância avaliada mediante o índice d também é superior a 0,9, bem como a correlação forte representada por r (Tabela 1). Porém, a performance do ECMWF é um pouco superior àquela apresentada pelo CFSv2, uma vez que o viés global é menor e as demais estatísticas são superiores. Ressalta-se que o SDE está inserido em uma região de baixa previsibilidade climática, dado que o clima desse setor é menos dependente das variações lentas do estado oceânico e mais influenciado pela variabilidade caótica interna, associada às instabilidades e não linearidades do escoamento atmosférico (SAMPAIO e SILVA DIAS, 2014; YNOUE et al., 2017). No período chuvoso, os fenômenos que contribuem para a ocorrência de precipitação nessa região são controlados principalmente pelas condições de umidade e instabilidade do ar, assim como por sistemas meteorológicos transientes como as frentes frias (SAMPAIO e SILVA DIAS, 2014). Neste contexto, é válido destacar a performance de ambos os modelos globais na previsão sazonal de precipitação para essa região de baixa previsibilidade climática.

Figura 3 – Médias regionais sazonais de precipitação média (mm/dia) previstas pelo CFSv2 (em magenta) e ECMWF (em azul) e observada pela análise CPC (em preto) nas quatro regiões em estudo: a) SDE, b) SUL, c) NEB e d) AMZ.



Fonte: Elaborado pelos autores (2020).

O SDE (Figura 3a) apresenta um ciclo anual de precipitação mais homogêneo (sem muita variabilidade entre as estações do ano) do que as demais regiões do Brasil (NERY et al., 2006; GRIMM, 2009; REBOITA et al., 2010, 2012; DE JESUS et al., 2016). Em ambas as previsões, é possível observar um viés positivo que indica superestimativa da precipitação em todo o período de análise (Tabela 1), concordando com os resultados da Figura 2. Além da superestimativa da precipitação, é possível ainda observar que ambos os modelos não conseguem reproduzir com tanta qualidade o padrão de precipitação, o que reflete nas estatísticas (Tabela 1), pois o ajuste é regular ($R^2 \sim 0,44$), assim como a concordância ($d \sim 0,55$), e a correlação é moderada ($r \sim 0,66$). Vários fatores podem estar associados a essa deficiência dos modelos em representar satisfatoriamente os valores da precipitação como, por exemplo, os esquemas de parametrização de precipitação de grande escala que podem superestimar a

chuva associada com a passagem frequente de sistemas frontais pela região. Destaca-se que a região Sul é fortemente influenciada por sistemas sinóticos (como frentes e ciclones extratropicais) que possuem variabilidade temporal mais rápida do que a dos efeitos das condições de contorno com variações mais lentas, como aquelas associadas à TSM (YNOUE et al., 2017). Tais características de circulação atmosférica tornam a previsão climática sazonal mais complexa para os extratropicais, conferindo uma média previsibilidade climática pelos modelos para essa região (SAMPAIO e SILVA DIAS, 2014; YNOUE et al., 2017).

O NEB (Figura 3c) conta com um ciclo anual de precipitação marcado por máximos pluviométricos durante o primeiro semestre (verão e outono) (KAYANO e ANDREOLI, 2009; REBOITA et al., 2010, 2012, 2016; MARENGO et al., 2018; TINÔCO et al., 2018). Ambos os modelos representam bem o padrão do ciclo anual da chuva, porém o ECMWF representa com qualidade superior o comportamento anual da precipitação quando comparado ao CFSv2. Isso também é perceptível pelas demais estatísticas do ECMWF, entre as quais R^2 , d e r são superiores a 0,9 e àquelas obtidas pelo CFSv2 (Tabela 1). Resultado semelhante foi obtido por Gubler et al. (2020) que, analisando as previsões sazonais retrospectivas (*hindcasts*) de precipitação do ECMWF-SEAS5 de 1981 a 2016, concluíram que o modelo europeu apresentou alto desempenho em prever a chuva no Nordeste brasileiro, com as maiores correlações (entre os valores previstos e observados) nos trimestres de MAM a MJJ. Os autores sugerem que a forte influência do fenômeno El Niño-Oscilação Sul (ENOS) sobre a precipitação na região Nordeste seja uma importante razão para o alto desempenho da previsão climática de chuva do ECMWF nesse setor. Salienta-se que é possível fazer previsões de confiabilidade relativamente alta para a região Nordeste, devido à sua grande dependência com o estado dos oceanos Atlântico e Pacífico tropicais (SAMPAIO e SILVA DIAS, 2014). Dado que, nos trópicos, as condições de estado oceânico dominam a variabilidade interanual do clima, a previsibilidade climática torna-se mais alta que nos extratropicais (CHARNEY e SHUKLA, 1981; PALMER e ANDERSON, 1994).

A AMZ (Figura 3d) possui um ciclo anual de precipitação espacialmente heterogêneo e abundante principalmente nos meses de verão e outono (REBOITA et al., 2010, 2012; DEBORTOLI et al., 2015; SANTOS et al., 2015; DE AZEVEDO, et al., 2017; COUTINHO et al., 2018; MARRAFON e REBOITA, 2020). Ambas as previsões conseguem reproduzir o padrão do ciclo anual pluviométrico, porém o CFSv2 apresenta condições mais úmidas durante o verão e outono e secas no inverno e primavera, enquanto o ECMWF é mais úmido entre a primavera

e outono. Em geral, o viés do CFSv2 é negativo e o do ECMWF é positivo (Tabela 1). Em relação às demais estatísticas (Tabela 1), é possível observar que o CFSv2 consegue ter previsões com qualidade superior às do ECMWF, uma vez que R^2 , d e r são superiores aos obtidos pelo ECMWF. De forma similar, Gubler et al. (2020) verificaram que o desempenho do ECMWF em prever sazonalmente a precipitação na região amazônica foi muito baixo, com valores de correlação abaixo de 0,3 nesse setor.

De forma geral, comparando-se as estatísticas para cada subdomínio em estudo, observa-se que as previsões de precipitação para o SDE e NEB foram melhor simuladas pelo ECMWF, enquanto para a AMZ foi o CFSv2. Por outro lado, para o SUL, o desempenho de ambos os modelos globais é similar.

Tabela 1 – Estatísticas para análise de desempenho das previsões de precipitação trimestral média de cada modelo climático (CFSv2 e ECMWF) em relação aos dados observados da análise do CPC. Resultados em azul indicam melhor desempenho.

| Subdomínio | Modelo Climático | viés | R^2 | d | r |
|------------|------------------|--------|-------|-------|-------|
| SDE | CFSv2 | 0,767 | 0,918 | 0,937 | 0,958 |
| | ECMWF | 0,765 | 0,956 | 0,954 | 0,978 |
| SUL | CFSv2 | 1,561 | 0,444 | 0,545 | 0,667 |
| | ECMWF | 1,389 | 0,436 | 0,571 | 0,660 |
| NEB | CFSv2 | 1,023 | 0,858 | 0,863 | 0,926 |
| | ECMWF | 0,244 | 0,952 | 0,977 | 0,976 |
| AMZ | CFSv2 | -0,400 | 0,824 | 0,928 | 0,908 |
| | ECMWF | 1,075 | 0,752 | 0,878 | 0,867 |

CONCLUSÃO

Este estudo teve como objetivo avaliar a performance das previsões sazonais climáticas de precipitação do CFSv2 e ECMWF para o Brasil mediante o padrão espacial e estatísticas (viés, R^2 , d e r) aplicadas em quatro subdomínios nacionais.

Ambos os modelos conseguiram representar a distribuição espacial da precipitação observada pela análise do CPC, porém o CFSv2 subestima o volume de precipitação em grande parte da região Norte, enquanto o ECMWF se mostra mais úmido nesta região. Além disso, ambos os modelos indicam um viés úmido na região Sul em todas as estações do ano. Em uma análise sazonal, observou-se que as previsões apresentaram melhores resultados durante o inverno, uma vez que há uma redução das chuvas em grande parte do país. No entanto, é válido mencionar que a amostra temporal utilizada neste estudo é relativamente pequena

(pouco mais de um ano de dados), mas com a maioria dos trimestres ocorrendo no período de neutralidade do fenômeno El Niño-Oscilação Sul (ENOS; CPC, 2021). Neste contexto, pode-se considerar as composições como representativas do clima médio dos períodos analisados.

Com relação aos critérios estatísticos, em geral, os dois modelos conseguem prever a precipitação nos subdomínios SDE, NEB e AMZ, com maiores diferenças no subdomínio AMZ. Contudo, no subdomínio SUL, o desempenho das previsões do CFSv2 e ECMWF é menor quando comparado ao desempenho obtido nos outros subdomínios. Isso pode ser uma consequência da grande variabilidade da atuação dos sistemas atmosféricos de latitudes médias que afetam o sul do país. Em resumo, as previsões climáticas sazonais dos modelos globais validados apresentam potencial de aplicação no Brasil, observadas suas limitações e acuracidades espacial e temporal.

Explicar a causa física dos vieses dos modelos climáticos é uma tarefa árdua e que está além do escopo deste estudo, uma vez que envolve muitos fatores como condições iniciais, física do modelo, entre outros, que afetam os balanços de radiação e água na superfície (PEIXOTO e OORT, 1992). Por fim, conclui-se que ambos os modelos podem ser utilizados para previsões sazonais de precipitação no Brasil.

AGRADECIMENTOS

Os autores agradecem aos centros que disponibilizam os dados utilizados no estudo e ao auxílio financeiro do CNPq, FAPEMIG e CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil - Código de Financiamento 001).

REFERÊNCIAS

ALENCAR, A. J.; SCHMITZ, E. A. **Análise de risco em gerência de projetos**. 3a ed. Rio de Janeiro: Brasport, 2012.

ANDREOLI, R. V.; KAYANO, M. T.; SILVA, J. V.; OLIVEIRA, S. S.; SOUZA, R. A. F.; GARCIA, S. R.; REGO, W. H. T.; OLIVEIRA, M. B. L. Effects of two different La Niña types on the South American rainfall. **International Journal of Climatology**, v. 39, p. 1415-1428, 2018.

ASHFAQ, M.; CAVAZOS, T.; REBOITA, M. S.; TORRES-ALAVEZ, J. S.; IM, E. S.; OLUSEGUM, C. F.; ALVES, L.; KEY, K.; ADENIYI, M. O.; TALL, M.; SYLLA, M. B.; MEHMOOD, S.; ZAFAR, Q.; DAS, S.; DIALLO, I.; COPPOLA, E.; GIORGI, F. Robust late twenty-first century shift in the regional monsoons in RegCM-CORDEX simulations. **Climate Dynamics**, v. 57, p. 1463-1488, 2020.

BARNSTON, A. G.; TIPPETT, M. K.; L'HEUREUX, M. L.; LI, S.; DEWITT, D. G. Skill of real-time seasonal ENSO model predictions during 2002-11 – Is our capability increasing? **Bulletin of the American Meteorological Society**, v. 93, p. 631-651, 2012.

BECHTOLD, P.; SEMANE, N.; LOPEZ, P.; CHABOUREAU, J. P.; BELJAARS, A.; BORNMANN, N. Representing equilibrium and nonequilibrium convection in large-scale models. **Journal of the Atmospheric Sciences**, v. 71, p. 734-753, 2014.

BELLENGER, H.; GUILYARDI, E.; LELOUP, J.; LENGAIGNE, M.; VIALARD, J. ENSO representation in climate models: from CMIP3 to CMIP5. **Climate Dynamics**, v. 42, p. 1999-2018, 2014.

BUSSAY, A.; VAN DER VELDE, M.; FUMAGALLI, D.; SEGUINI, L. Improving operational maize yield forecasting in Hungary. **Agricultural Systems**, v. 141, p. 94-106, 2015.

CAPA-MOROCHO, M.; INES, A. V. M.; BAETHGEN, W. E.; RODRÍGUEZ-FONSECA, B.; HAN, E.; RUIZ-RAMOS, M. Crop yield outlooks in the Iberian Peninsula: connecting seasonal climate forecasts with crop simulation models. **Agricultural Systems**, v.149, p. 75-87, 2016.

CARDOSO, A. O.; PINTO, H. S.; ÁVILA, A. M. H.; SILVA DIAS, P. L.; MARIN, F. R.; PILAU, F. Extended time weather forecasts contributes to agricultural productivity estimates. **Theoretical and Applied Climatology**, v. 102, n. 3, p. 343-350, 2010.

CASTANHARO, G.; GIBERTONI, R. F. C.; MÜLLER, I. I.; ANDRIOLO, M. V.; KAVISKI, E.; GUILHON, L. G. F.; ROCHA, V. F. Previsão de vazões na Bacia do Rio Iguazu baseada no modelo SMAP e com incorporação de informações de precipitação. **Revista Brasileira de Recursos Hídricos**, v. 12, n. 3, p. 57-68, 2007.

CENTRO DE ESTUDOS AVANÇADOS EM ECONOMIA APLICADA – CEPEA-USP-CNA. **PIB do Agronegócio: 1995–2019**. 2020. Disponível em: <http://cepea.esalq.usp.br/pib/>. Acesso em: set. 2020.

CHARNEY, J. G.; SHUKLA, J. Predictability of monsoons. *In*: LIGHTHILL, J.; PEARCE, R. P. **Monsoon Dynamics**. Cambridge: Cambridge University Press, 1981. p. 99-110.

CHEN, M.; SHI, W.; XIE, P.; SILVA, V. B. S.; KOUSKY, V. E.; HIGGINS, R. W.; JANOWIAK, J. E. Assessing objective techniques for gauge-based analyses of global daily precipitation. **Journal of Geophysical Research**, v. 113, p. 1-13, 2008.

CHIPANSHI, A.; ZHANG, Y.; KOUADIO, L.; NEWLANDS, N.; DAVIDSON, A.; HILL, H.; WARREN, R.; QIAN, B.; DANESHFAR, B.; BEDARD, F.; REICHERT, G. Evaluation of the Integrated Canadian Crop Yield Forecaster (ICCYF) model for in-season prediction of crop yield across the Canadian agricultural landscape. **Agricultural and Forest Meteorology**, v. 206, p. 137-150, 2015.

COLLISCHONN, W.; TUCCI, C. E. M.; CLARKE, R. T.; DIAS, P. L. S.; DE OLIVEIRA, G. S. Previsão sazonal de vazão na Bacia do Rio Uruguai 2: previsão climática-hidrológica. **Revista Brasileira de Recursos Hídricos**, v. 10, n. 4, p. 61-72, 2005.



COSSICH, W.; CATALDI, M.; FILHO, O. C. R. Avaliação do desempenho da geração de cenários de afluências em reservatórios utilizando previsões de precipitação por conjunto. **Ciência e Natura**, v. 37, p. 55-62, 2015.

COUTINHO, E. C.; ROCHA, E. J. P.; LIMA, A. M. M.; RIBEIRO, H. M. C.; GUTIERREZ, L. A. C. L.; BARBOSA, A. J. S.; BARBOSA, A. J. S.; PAES, G. K. A. A.; BISPO, C. J. C.; TAVARES, P. A. Variabilidade climática da precipitação na Bacia Amazônica brasileira entre 1982 e 2012. **Revista Brasileira de Climatologia**, v. 22, p. 476-500, 2018.

CLIMATE PREDICTION CENTER – CPC. **Cold and warm episodes by season**. 2021. Disponível em:

https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php.

Acesso em: ago. 2021.

DARANI, S. M. M. M.; DASTJERDI, J. K.; STONE, R.; BABAEIAN, I.; ABBASI, F. Linking a general circulation model with a crop model to forecast barley yields: a case study for Isfahan, Iran. **International Journal of AYER**, v. 2, p. 451-469, 2015.

DE AZEVEDO, F. T. M.; DE SOUZA, E. B.; FRANCO, V. S.; SOUZA, P. F. S. Prognóstico sazonal de precipitação regionalizada na Amazônia Oriental. **Revista Brasileira de Geografia Física**, v. 10, n. 5, p. 1520-1534, 2017.

DE JESUS, E. M.; DA ROCHA, R. P.; REBOITA, M. S.; LLOPART, M.; DUTRA, L. M. M.; REMEDIO, A. R. C. Contribution of cold fronts to seasonal rainfall in simulations over the Southern La Plata Basin. **Climate Research**, v. 68, n. 2-3, p. 243-255, 2016.

DE PAIVA, L. F. G.; MONTENEGRO, S. M.; CATALDI, M. Prediction of monthly flows for the Três Marias reservoir (São Francisco River Basin) using the CFS climate forecast model. **Revista Brasileira de Recursos Hídricos**, v. 25, n. 16, p. 1-18, 2020.

DE QUADRO, M. F. L.; PEZZI, L. P.; ROSA, E. B. O climanálise e o monitoramento da ZCAS nos últimos 30 anos. **Revista Climanalise**: edição comemorativa 30 anos, p. 19-25, 2016.

DE SOUZA, I. P.; ANDREOLI, R. V.; KAYANO, M. T.; VARGAS, F. F.; CERÓN, W. L.; MARTINS, J. A.; FREITAS, E.; SOUZA, R. A. F. Seasonal precipitation variability modes over South America associated to El Niño-Southern Oscillation (ENSO) and non-ENSO components during the 1951-2016 period. **International Journal of Climatology**, v. 41, p. 4321-4338, 2021.

DEBORTOLI, N. S.; DUBREUIL, V.; FUNATSU, B.; DELAHAYE, F.; OLIVEIRA, C. H.; RODRIGUES-FILHO, S.; SAITO, C. H.; FETTER, R. Rainfall patterns in the Southern Amazon: a chronological perspective (1971-2010). **Climate Change**, v. 132, n. 2, p. 251-264, 2015.

DIAS, T. L.; CATALDI, M.; FERREIRA, V. H. Aplicação de técnicas de redes neurais e modelagem atmosférica para elaboração de previsões de vazão na Bacia do Rio Grande (MG). **Engenharia Sanitária e Ambiental**, v. 22, n. 1, p. 169-178, 2017.

DIRMEYER, P. A.; FENNESSY, M. J.; MARX, L. Low skill in dynamical prediction of boreal summer climate: grounds for looking beyond sea surface temperature. **Journal of Climate**, v. 16, n. 6, p. 995-1002, 2003.



DIRMEYER, P. A.; SCHLOSSER, C. A.; BRUBAKER, K. L. Precipitation, recycling, and land memory: an integrated analysis. **Journal of Hydrometeorology**, v. 10, n. 1, p. 278-288, 2009.

DOBLAS-REYES, F. J.; GARCÍA-SERRANO, J.; LIENERT, F.; BIESCAS, A. P.; RODRIGUES, L. R. L. Seasonal climate predictability and forecasting: status and prospects. **WIREs Climate Change**, v. 4, p. 245-268, 2013.

DU, Y.; XIE, S-P.; YANG, Y-L.; ZHENG, X-T.; LIU, L.; HUANG, G. Indian Ocean variability in the CMIP5 multimodel ensemble: the basin mode. **Journal of Climate**, v. 26, p. 7240-7266, 2013.

DUMONT, B.; BASSO, B.; LEEMANS, V.; BODSON, B.; DESTAIN, J. P.; DESTAIN, M. F. A comparison of within-season yield prediction algorithms based on crop model behaviour analysis. **Agricultural and Forest Meteorology**, v. 204, p. 10-21, 2015.

EUROPEAN CENTRE FOR MEDIUM-RANGE WEATHER FORECASTS – ECMWF. **SEAS5 User Guide**. 2017.

FAN, F. M.; COLLISCHONN, W.; MELLER, A.; BOTELHO, L. C. M. Ensemble streamflow forecasting experiments in a tropical basin: the São Francisco River case study. **Journal of Hydrology**, v. 519, p. 2906-2919, 2014.

FIGUEIREDO, K.; BARBOSA, C. R. H.; DA CRUZ, A. V. A.; VELLASCO, M.; PACHECO, M. A. C.; CONTRERAS, R. J.; BARROS, M.; SOUZA, R. C.; MARQUES, V. S.; DUARTE, U. M.; MENDES, M. H. Modelo de previsão de vazão com informação de precipitação utilizando redes neurais. **Revista Brasileira de Recursos Hídricos**, v. 12, n. 3, p. 69-82, 2007.

GIORGI, F.; MEARNS, L. O. Introduction to special section: Regional climate modeling revisited. **Journal of Geophysical Research**, v. 104, n. D6, p. 6335-6352, 1999.

GRIMM, A. M. Clima da região Sul do Brasil. In: CAVALCANTI, I. F. A. **Tempo e clima no Brasil**. São Paulo: Oficina de Textos, 2009. p. 259-275.

GRIMM, A. M.; BARROS, V. R.; DOYLE, M. E. Climate variability in southern South America associated with El Niño and La Niña events. **Journal of Climate**, v. 13, p. 35-58, 2000.

GRIMM, A. M.; FERRAZ, S. E. T.; GOMES, J. Precipitation anomalies in Southern Brazil associated with El Niño and La Niña events. **Journal of Climate**, v. 11, p. 2863-2880, 1998.

GUBLER, S.; SEDLMEIER, K.; BHEND, J.; AVALOS, G.; COELHO, C. A. S.; ESCAJADILLO, Y.; JACQUES-COPER, M.; MARTINEZ, R.; SCHWIERZ, C.; DE SKANSI, M.; SPIRIG, C. Assessment of ECMWF SEAS5 seasonal forecast performance over South America. **Weather and Forecasting**, v. 35, p. 561-584, 2020.

HAM, Y-G.; KUG, J-S. How well do climate models simulate two types of El Niño? **Climate Dynamics**, v. 39, p. 383-398, 2012.

JOHNSON, S. J.; STOCKDALE, T. N.; FERRANTI, L.; BALSAMEDA, M. A.; MOLTENI, F.; MAGNUSSON, L.; TIETSCHKE, S.; DECREMERS, D.; WEISHEIMER, A.; BALSAMO, G.; KEELEY, S. P. E.; MOGENSEN, K.; ZUO, H.; MONGE-SANZ, B. M. SEAS5: the new ECMWF seasonal forecast system. **Geoscientific Model Development**, v. 12, p. 1087-1117, 2019.



KAYANO, M. T.; ANDREOLI, R. V. Clima da região Nordeste do Brasil. *In*: CAVALCANTI, I. F. A. **Tempo e clima no Brasil**. São Paulo: Oficina de Textos, 2009. p. 213-233.

KUG, J-S.; HAM, Y-G. Are there two types of La Niña? **Geophysical Research Letters**, v. 38, L16704, 2011.

KUG, J-S.; HAM, Y-G.; LEE, J-Y.; JIN, F-F. Improved simulation of two types of El Niño in CMIP5 models. **Environmental Research Letters**, v. 7, 034002, 2012.

LEMES, M. C. R.; REBOITA, M. S. Elementos fisiográficos e a precipitação no Estado de São Paulo. *In*: PINHEIRO, L. S.; GPRAYED, A. **Geografia física e as mudanças globais**. Fortaleza: UFC, 2019. p. 1-15.

LI, H.; LUO, L.; WOOD, E. F.; SCHAAKE, J. The role of initial conditions and forcing uncertainties in seasonal hydrologic forecasting. **Journal of Geophysical Research**, v. 114, p. D04114, 2009.

LLOPART, M. P.; REBOITA, M. S.; DA ROCHA, R. P.; MACHADO, J. P. Performance do acoplamento RegCM4.3 e CLM3.5: uma análise sobre o sudeste do Brasil. **Anuário do Instituto de Geociências**, v. 41, n. 3, p. 113-124, 2018.

MADEC, G. **NEMO Ocean Engine**. 2020. Disponível em: https://www.nemo-ocean.eu/wp-content/uploads/NEMO_book.pdf. Acesso em: set. 2020.

MALHERBE, J.; LANDMAN, W. A.; OLIVIER, C.; SAKUMA, H.; LUO, J-J. Seasonal forecasts of the SINTEX-F coupled model applied to maize Yield and streamflow estimates over north-eastern South Africa. **Meteorological Applications**, v. 21, p. 733–742, 2014.

MARENGO, J. A.; ALVES, L. M.; ALVALA, R. C. S.; CUNHA, A. P.; BRITO, S.; MORAES, O. L. L. Climatic characteristics of the 2010-2016 drought in the semiarid Northeast Brazil region. **Anais da Academia Brasileira de Ciências**, v. 90, p. 1973-1985, 2018.

MARENGO, J. A.; LIEBMANN, B.; GRIMM, A. M. MISRA; V.; DIAS; P. L. S.; CAVALCANTI, I. F. A.; CARVALHO, L. M. V.; BERBERY, E. H.; AMBRIZZI, T.; VERA, C. S.; SAULO, A. C.; NOGUES-PAEGLE, J.; ZIPSER, E.; SETH, A.; ALVES, L. M. Recent developments on the South America monsoon system. **International Journal of Climatology**, v. 32, n. 1, p. 1-21, 2012.

MARRAFON, V. H.; REBOITA, M. S. Características da precipitação na América do Sul reveladas através de índices climáticos. **Revista Brasileira de Climatologia**, v. 16, p. 663-676, 2020.

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

MEEHL, G. A.; RICHTER, J. H.; TENG, H.; CAPOTONDI, A.; COBB, K.; DOBLAS-REYES, F.; DONAT, M. G.; ENGLAND, M. H.; FYFE, J. C.; HAN, W.; KIM, H.; KIRTMAN, B. P.; KUSHNIR, Y.; LOVENDUSKI, N. S.; MANN, M. E.; MERRYFIELD, W. J.; NIEVES, V.; PEGION, K.; ROSENBLOOM, N.; SANCHEZ, S. C.; SCAIFE, A. A.; SMITH, D.; SUBRAMANIAN, A. C.; SUN, L.; THOMPSON, D.;

UMMENHOFER, C. C.; XIE, S. P. Initialized Earth System prediction from subseasonal to decadal timescales. **Nature Reviews Earth & Environment**, v. 2, p. 340–357, 2021.

MOLTENI, F.; STOCKDALE, T.; BALSAMEDA, M.; BALSAMO, G.; BUIZZA, R.; FERRANTI, L.; MAGNUSSON, L.; MOGENSEN, K.; PALMER, T.; VITART, F. **The new ECMWF seasonal forecast system (System 4)**. ECMWF Technical Memorandum, v. 656, 2011.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to time series analysis and forecasting**. 2. ed. New Jersey: John Wiley & Sons, 2015.

MORETO, V. B.; ROLIM, G. S.; ESTEVES, J. T.; VANUYTRECHT, E.; CHOU, S. C. Sugarcane decision-making support using ETA Model precipitation forecasts. **Meteorology and Atmospheric Physics**, 2020.

NERY, J. T.; DENIG, E. A.; AZEVEDO, L. C.; MARTINS, M. L. O. F. Estudo da variabilidade interanual da precipitação na Bacia do Rio Uruguai. **Revista Brasileira de Recursos Hídricos**, v. 11, n. 2, p. 149-159, 2006.

OETTLI, P.; SULTAN, B.; BARON, C.; VRAC, M. Are regional climate models relevant for crop yield prediction in West Africa? **Environmental Research Letters**, v. 6, n.014008, 2011.

OKUMURA, Y. M.; DESER, C. Asymmetry in the duration of El Niño and La Niña. **Journal of Climate**, v. 23, p. 5826-5843, 2010.

PALMER, T. N.; ANDERSON, D. L. T. The prospects for seasonal forecasting – a review paper. **Quarterly Journal of the Royal Meteorological Society**, v. 120, n. 518, p. 755-793, 1994.

PEIXOTO, J. P.; OORT, A. H. **Physics of climate**. Heidelberg: Springer, 1992.

PIEDRA-BONILLA, E. B.; DA CUNHA, D. A.; BRAGA, M. J. Climate variability and crop diversification in Brazil: an ordered probit analysis. **Journal of Cleaner Production**, v. 256, p. 1-10, 2020.

PONTES, P. R. M.; FAN, F. M.; COLLISCHONN, W.; PAIVA, R. C. D. Análise da sensibilidade da vazão do Rio paraná a potencial alteração da precipitação. XX Simpósio Brasileiro de Recursos Hídricos, 2013.

PRESS, W. H.; TEUKOLSKY, S. A.; VETTERLING, W. T.; FLANNERY, B. P. **Numerical recipes: The art of scientific computing**. 3. ed. New York: Cambridge University Press, 2007.

REBOITA, M. S.; AMBRIZZI, T.; CRESPO, N. M.; DUTRA, L. M. M.; FERREIRA, G. W. S.; REHBEIN, A.; DRUMOND, A.; ROCHA, R. P.; SOUZA, C. A. Impacts of teleconnection patterns on South America climate: a review. **Annals of the New York Academy of Sciences**, 2021.

REBOITA, M. S.; DIAS, C. G.; DUTRA, L. M. M.; DA ROCHA, R. P.; LLOPART, M. 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, 2018.



REBOITA, M. S.; GAN, M. A.; DA ROCHA, R. P.; AMBRIZZI, T. Regimes de precipitação na América do Sul: uma revisão bibliográfica. **Revista Brasileira de Meteorologia**, v. 25, n. 2, p. 185-204, 2010.

REBOITA, M. S.; KRUSCHE, N.; AMBRIZZI, T.; DA ROCHA, R. P. Entendendo o tempo e o clima na América do Sul. **Revista Terræ Didática**, v. 8, n. 1, p. 34-50, 2012.

REBOITA, M. S.; RODRIGUES, M.; ARMANDO, R. P.; FREITAS, C.; MARTINS, D.; MILLER, G. Causas da semiaridez no sertão nordestino. **Revista Brasileira de Climatologia**, v. 19, p. 254-277, 2016.

ROBERTSON, A. W.; VITART, F. Sub-seasonal to seasonal prediction. **The gap between weather and climate forecasting**. Amsterdam: Elsevier, 2019.

ROBERTSON, A. W.; VITART, F.; CAMARGO, S. J. Subseasonal to seasonal prediction of weather to climate with application to tropical cyclones. **Journal of the Geophysical Research: Atmospheres**, v. 125, e2018JD029375, 2020.

RODRIGUES, R. R.; MCPHADEN, M. J. Why did the 2011-2012 La Niña cause a severe drought in the Brazilian Northeast? **Geophysical Research Letters**, v. 41, p. 1012-1018, 2014.

ROGERS, J. C.; Precipitation variability over the Caribbean and tropical Americas associated with the Southern Oscillation. **Journal of Climate**, v. 1, p. 172-182, 1988.

SAHA, S. et al. The NCEP Climate Forecast System Reanalysis. **American Meteorological Society**, v. 91, n. 8, p. 1015-1057, 2010.

SAHA, S. et al. The NCEP Climate Forecast System version 2. **Journal of Climate**, v. 27, n. 6, p. 2185-2208, 2014.

SAMPAIO, G.; SILVA DIAS, P. L. Evolução dos modelos climáticos e de previsão de tempo e clima. **Revista USP**, n. 103, p. 41-54, 2014.

SANTOS, E. B.; LUCIO, P. S.; SILVA, C. M. S. Precipitation regionalization of the Brazilian Amazon. **Atmospheric Science Letters**, v. 16, p. 185-192, 2015.

SANTOSO, A.; ENGLAND, M. H.; CAI, W. Impact of Indo-Pacific feedback interactions on ENSO dynamics diagnosed using ensemble climate simulations. **Journal of Climate**, v. 25, p. 7743-7763.

SILVA, E. D.; REBOITA, M. S. Estudo da precipitação no Estado de Minas Gerais – MG. **Revista Brasileira de Climatologia**, v. 13, p. 120-136, 2013.

SILVA, G. A. M.; DUTRA, L. M. M.; DA ROCHA, R. P.; AMBRIZZI, T.; LEIVA, E. Preliminary analysis on the global features of the NCEP CFSv2 seasonal hindcasts. **Advances in Meteorology**, v. 2014, p. 1-21, 2014.

SILVA, J. P. R.; REBOITA, M. S.; ESCOBAR, G. C. J. Caracterização da zona de convergência do Atlântico Sul em campos atmosféricos recentes. **Revista Brasileira de Climatologia**, v. 25, p. 355-377, 2019.

SUN, Q.; MIAO, C.; DUAN, Q.; ASHOURI, H.; SOROOSHIAN, S.; HSU, K.-L. A review of global precipitation data sets: data sources, estimation, and intercomparisons. **Reviews of Geophysics**, v. 56, p. 79-107, 2018.

TASCHETTO, A. S.; SEN GUPTA, A.; JOURDAIN, N. C.; SANTOSO, A. Cold tongue and warm pool ENSO events in CMIP5: mean state and future projections. **Journal of Climate**, v. 27, p. 2861-2885, 2014.

TEDESCHI, R. G.; CAVALCANTI, I. F. A.; GRIMM, A. M. Influences of two types of ENSO on South American precipitation. **International Journal of Climatology**, v. 33, p. 1382-1400, 2013.

TEDESCHI, R. G.; COLLINS, M. The influence of ENSO on South American precipitation during austral summer and autumn in observations and models. **International Journal of Climatology**, v. 36, p. 618-635, 2016.

TINÔCO, I. C. M.; BEZERRA B. G.; LUCIO, P. S.; BARBOSA, L. M. Characterization of rainfall patterns in the semiarid Brazil. **Anuário do Instituto de Geociências**, v. 41, n. 2, p. 397-409, 2018.

TORRES, F. L. R.; FERREIRA, G. W. S.; KUKI, C. A. C. et al. Validação de diferentes bases de dados de precipitação nas bacias hidrográficas do Sapucaí e São Francisco. **Revista Brasileira de Climatologia**, v. 27, p. 368-404, 2020.

VITART, F.; ROBERTSON, A. W. The sub-seasonal to seasonal prediction project (S2S) and the prediction of extreme events. **npj Climate and Atmospheric Science**, v. 1, 3, 2018.

WANG, B. LIU, J. KIM, H. J. et al. (2012) Recent change of the global monsoon precipitation (1979-2008). **Climate Dynamics**, v. 39, p. 1123-1135.

WANG, C. Three-ocean interactions and climate variability: a review and perspective. **Climate Dynamics**, v. 53, p. 5119-5136, 2019.

WIEDERMANN, M.; SIEGMUND, J. F.; DONGES, J. F.; DONNER, R. V. Differential imprints of distinct ENSO flavors in global patterns of very low and high seasonal precipitation. **Frontiers in Climate**, v. 3, 618548, 2021.

WILKS, D. S. **Statistical methods in the atmosphere sciences**. 3. ed. Amsterdam: Elsevier, 2011.

WILLMOTT, C. J. On the validation of models. **Physical Geography**, v. 2, p. 184–194, 1981.

WORLD METEOROLOGICAL ORGANIZATION – WMO. **State of the Global Climate 2020** (WMO-Nº 1264). Geneva, 2021.

XU, K.; SU, J. Z.; ZHU, C. W.; The natural oscillation of two types of ENSO events based on analyses of CMIP5 model control runs. **Advances in Atmospheric Sciences**, v. 31, p. 801-813, 2014.

YNOUE, R. Y.; REBOITA, M. S.; AMBRIZZI, T. SILVA, G. A. M. **Meteorologia: noções básicas**. São Paulo: Oficina de Textos, 2017.



ZINYENGERE, N.; MHIZHA, T.; MASHONJOWA, E.; CHIPINDU, B.; GEERTS, S.; RAES, D. Using seasonal climate forecasts to improve maize production decision support in Zimbabwe. **Agricultural and Forest Meteorology**, v.151, p. 1792–1799, 2011.