



“DRIVERS” DA PREVISÃO CLIMÁTICA SAZONAL: UMA REVISÃO DA LITERATURA

Seasonal climate forecast “Drivers”: a literature review

“Conductores” del pronóstico del clima estacional: una revisión de la literatura

Michelle Simões Reboita  

Universidade Federal de Itajubá (UNIFEI), Itajubá, MG, Brasil
reboita@unifei.edu.br

Cassia Akemi Castro Kuki  

Universidade Federal de Itajubá (UNIFEI), Itajubá, MG, Brasil
cassiakuki@unifei.edu.br

Glauber Willian de Souza Ferreira  

Universidade Federal de Itajubá (UNIFEI), Itajubá, MG, Brasil
glauber_ferreira@unifei.edu.br

Francisca Lanai Ribeiro Torres 

Universidade Federal de Itajubá (UNIFEI), Itajubá, MG, Brasil
lanai.torres@unifei.edu.br

Luana Medeiros Marangon Lima  

Duke University, Durham, Estados Unidos
lmm89@duke.edu

José Wanderley Marangon Lima  

Marangon Consultoria e Engenharia (MC&E), Itajubá, MG, Brasil
jose.marangon@marangonenergia.com.br

Resumo: O clima de um determinado local é definido pelo valor médio das variáveis atmosféricas registradas por longo período. Entretanto, por exemplo, o valor registrado de precipitação numa dada estação do ano

pode ser bem diferente do valor médio, indicando a variabilidade do clima, o que pode ser muito prejudicial para a economia. Sendo assim, é importante o prognóstico do clima sazonal. Nesse enfoque, o presente estudo tem como objetivos compilar e apresentar didaticamente os conceitos e etapas envolvidos na previsão climática sazonal, bem como uma visão geral dos principais centros climáticos que fazem esse tipo de previsão. Além disso, o trabalho discorre sobre os mecanismos de variabilidade climática natural e sua importância para as previsões numéricas do clima. Assim, este estudo servirá de referência básica para as diferentes áreas do conhecimento que necessitam entender e utilizar as previsões climáticas.

Palavras-chave: Variabilidade climática natural. Teleconexões. América do Sul. Previsão climática.

Abstract: The climate of a given location is defined by the average value of the atmospheric variables recorded over a long period. However, for example, the recorded value of precipitation in a given season of the year can be quite different from the average value, indicating climate variability, which can be very harmful to the economy. Therefore, it is important to predict the seasonal climate. In this approach, this study aims to compile the knowledge needed to understand what climate is on a seasonal scale, the drivers (forcing) of its natural variability and how numerical climate forecasts are carried out. Thus, this study will serve as a basic reference for different areas of knowledge that need to understand and use climate forecasts.

Keywords: Natural climate variability. Teleconnections. South America. Climate forecast.

Resumen: El clima de un determinado lugar se define por el valor medio de las variables atmosféricas registradas durante un largo período. Sin embargo, por ejemplo, el valor registrado de precipitación en una determinada estación del año puede ser muy diferente del valor promedio, lo que indica la variabilidad del clima, que puede ser muy perjudicial para la economía. Por lo tanto, es importante predecir el clima estacional. En este enfoque, el presente estudio tiene como objetivo recopilar y presentar de manera didáctica los conceptos y pasos involucrados en el pronóstico climático estacional, así como una descripción general de los principales centros climáticos que realizan este tipo de pronóstico. Además, el trabajo discute los mecanismos de la variabilidad climática natural y su importancia para las predicciones climáticas numéricas. Por lo tanto, este estudio servirá como referencia básica para las diferentes áreas de conocimiento que necesitan entender y utilizar los pronósticos climáticos.

Palabras clave: Variabilidad natural del clima. Teleconexiones. América del Sur. Pronóstico del tiempo.

Submetido em: 06/10/2021

Aceito para publicação em: 07/07/2022

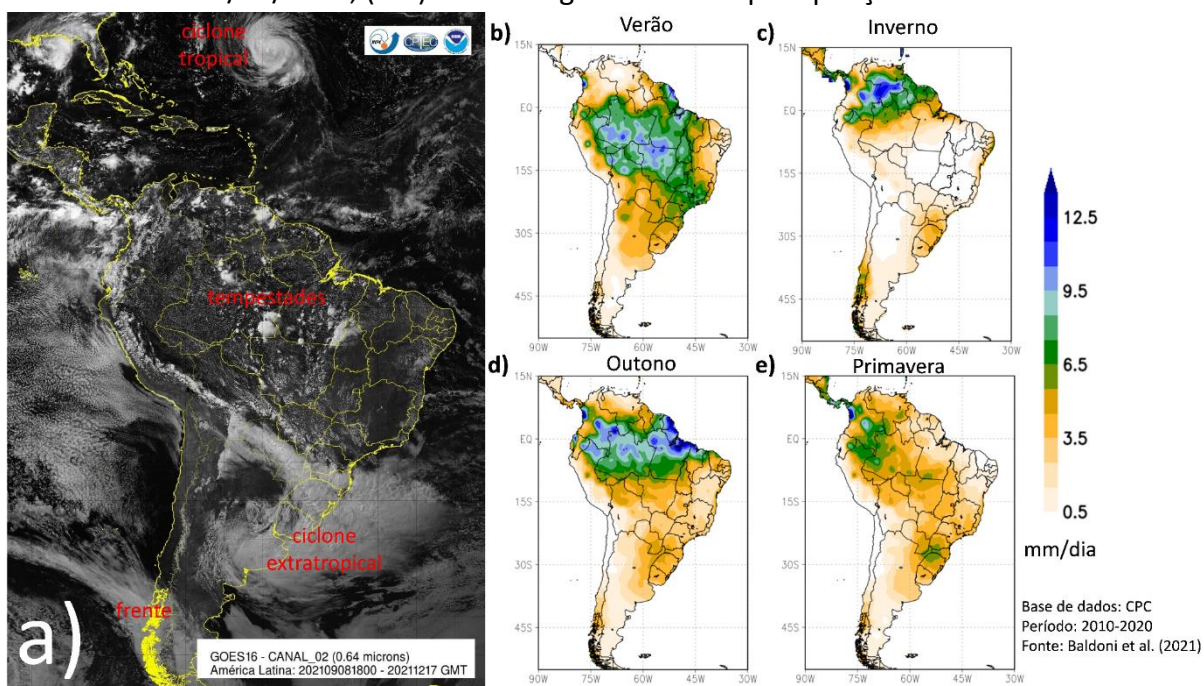
Publicado em: 29/07/2022



1. INTRODUÇÃO

O tempo e o clima são fatores naturais que influenciam diretamente as atividades humanas. Reboita et al. (2012) e Wang (2019) definem o *tempo* como sendo o estado momentâneo da atmosfera e o *clima* como a média das condições atmosféricas durante um longo período (**Figura 1**), normalmente de 30 anos (WMO, 2018). A partir das definições de tempo e clima, pode-se ainda diferenciá-los no contexto de previsão. Isso porque as *previsões de tempo* são consideradas como um problema de condição inicial e apresentam horizonte temporal de até duas semanas, embora não seja possível prever com precisão as mudanças diárias no tempo além de uma semana devido ao efeito do caos (LORENZ, 1963, 1972; PIELKE et al., 1999). De outro modo, as *previsões de clima* são consideradas como um problema de condição de contorno, com parâmetros climáticos de variabilidade temporal lenta como, por exemplo, a temperatura da superfície do mar (TSM) e a umidade do solo. As previsões de clima podem apresentar diferentes horizontes temporais: sub-sazonal, sazonal, interanual e decadal (PIELKE et al., 1999; TROCCOLI, 2010; DOBLAS-REYES et al., 2013; VITART e ROBERTSON, 2018; MEEHL et al., 2021).

Figura 1 - (a) Imagem de satélite mostrando a atuação de diferentes sistemas atmosféricos às 18 UTC do dia 08/09/2021; (b-e) Climatologia sazonal da precipitação na América do Sul.



Fontes: Centro de Previsão de Tempo e Estudos Climáticos - CPTEC (2021) e Baldoni et al. (2021).

Na previsão de tempo, o interesse consiste na predição com maior acurácia do local de ocorrência e momento de atuação dos sistemas atmosféricos. Porém, como os dados medidos nos instrumentos meteorológicos não são livres de erros e também há incertezas relacionadas às aproximações nas equações que descrevem o comportamento atmosférico, tem-se que os pequenos desvios em relação ao estado observado da atmosfera se propagam nas simulações numéricas e podem gerar previsões errôneas (LORENZ, 1972; SHUKLA, 1981; SIMMONS e HOLLINGSWORTH, 2002; YNOUE et al., 2017). Já na previsão climática, o interesse consiste em simular os sistemas atmosféricos em um determinado período a fim de contribuir na média das variáveis atmosféricas. Dessa forma, prognostica-se se uma determinada estação do ano, por exemplo, será mais quente ou fria, úmida ou seca do que a média climatológica de um dado local (BARRY e CHORLEY, 2010; YNOUE et al., 2017).

Se o clima de um determinado local corresponde a um padrão médio sazonal, que é decorrente de uma certa “regularidade” da ação dos sistemas atmosféricos típicos daquele local, o que conduz à variabilidade desse padrão em determinados períodos como, por exemplo, um menor (maior) número de frentes frias propiciando um inverno mais seco (chuvoso)? A resposta está relacionada com os drivers (forçantes) que causam alterações no padrão da circulação atmosférica modificando a intensidade e/ou frequência dos sistemas atmosféricos. Um exemplo de fácil compreensão é o que ocorre em períodos de aquecimento anômalo da TSM no oceano Pacífico tropical leste. Esse aquecimento (que é a forçante) perturba a atmosfera que, para tentar voltar ao equilíbrio, dispersa ondas. Essas ondas, por sua vez, geram padrões anômalos de pressão na atmosfera, contribuindo para intensificar ou atenuar certos sistemas (REBOITA et al., 2021). Por exemplo, o caso do aquecimento da TSM mencionado, amplamente conhecido como fenômeno El Niño (CAI et al., 2021), conduz a movimentos subsidentes entre a região norte da América do Sul (AS) e litoral norte do Nordeste brasileiro. Na região Norte, esses movimentos se contrapõem aos ascendentes reduzindo a atividade convectiva, enquanto no Nordeste eles são dominantes implicando em condições de seca. Por outro lado, no sul do Brasil, o predomínio de anomalias de baixa pressão contribui para a canalização do jato de baixos níveis para tal região, incrementando a disponibilidade de umidade na atmosfera e levando a anomalias positivas de precipitação (REBOITA et al., 2021).



De forma resumida, anomalias na TSM causam perturbações na atmosfera que se propagam na forma de ondas e afetam a localização, intensidade e/ou frequência dos sistemas atmosféricos atuantes numa dada região que, por consequência, levam a alterações no valor médio esperado das variáveis precipitação e temperatura do ar, por exemplo. O nome dado aos eventos que ocorrem num dado local do globo e afetam o clima de regiões remotas é padrões de teleconexão (LIU e ALEXANDER, 2007; REBOITA et al., 2021). Os padrões de teleconexão são fenômenos naturais do clima e causam variabilidade climática (modificam o valor médio das variáveis atmosféricas em diferentes escalas temporais) em distintos locais do globo.

Portanto, nota-se que a previsão climática está intrinsecamente ligada a parâmetros climáticos com variações lentas, tais como a TSM, umidade do solo, gelo marinho e cobertura de neve (SHUKLA e KINTER, 2006). Para a previsão climática, o monitoramento das anomalias de TSM é essencial, pois ela controla a variabilidade climática na escala sazonal (NOBRE e SHUKLA, 1996). Além dela, a umidade do solo também exerce um papel importante na variabilidade do clima de algumas regiões.

A previsão climática não é uma tarefa fácil, pois vários padrões de teleconexões ocorrem concomitantemente. O desafio é entender se o impacto deles gera uma resposta combinada de forma a ampliar um dado efeito, ou se a resposta deles tende a ser oposta, o que enfraqueceria e/ou anularia os impactos esperados (REBOITA et al., 2021). Como a variabilidade temporal dos oceanos é menor do que a da atmosfera, em virtude dos diferentes valores de calor específico, o impacto das anomalias de TSM na atmosfera tem uma resposta defasada (TROCCOLI, 2010). Assim, se hoje há um padrão de El Niño, esse não desaparecerá nos dias seguintes, pois há uma persistência das características oceânicas, o que facilita a previsão climática dos meses subsequentes.

Em virtude da variabilidade natural do clima, as previsões em escala sazonal são muito importantes, pois auxiliam a tomada de decisão e mitigação dos efeitos das variações climáticas em diferentes setores socioeconômicos, tais como agricultura (JAMAL et al., 2018; MARTINS et al., 2018; RODRIGUEZ et al., 2018), infraestrutura urbana (THORND AHL et al., 2016; SIKDER et al., 2019; BRENDEL et al., 2020), saúde (ARMSTRONG et al., 2010; GUSTIN et al., 2018; SILVA et al., 2019), energia (DIAS et al., 2017; TORRALBA et al., 2017; DE PAIVA et al., 2020; KUKI, 2020; KUKI et al., 2020), entre outros.

Diante do exposto, o objetivo deste trabalho é apresentar de forma didática as etapas envolvidas na previsão climática sazonal, um panorama dos centros que fazem este tipo de previsão e, principalmente, os mecanismos que causam variabilidade natural no sistema climático.

2. NOÇÕES BÁSICAS DA PREVISÃO CLIMÁTICA

2.1. Tipos de Modelos

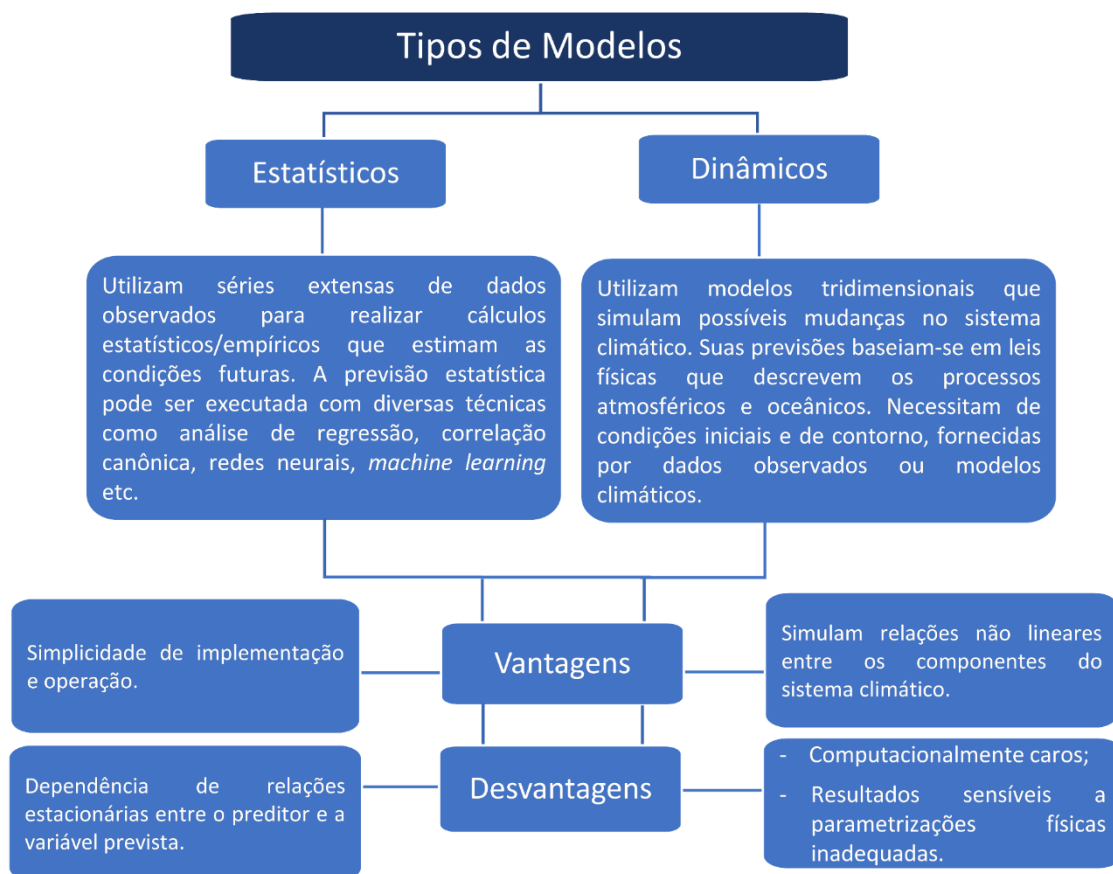
A previsão climática é mais complexa e desafiadora que a previsão do tempo, uma vez que envolve o problema do caos, a variabilidade interna do sistema climático modulada por forçantes com variações lentas (como, por exemplo, a TSM e a umidade do solo), bem como a influência de fatores externos ao clima (vide YNOUE et al., 2017 para detalhes sobre as forçantes externas). Os modelos que realizam essas previsões podem ser estatísticos ou dinâmicos (**Figura 2**). Embora existam diferenças substanciais entre os dois tipos de modelos, ambos exigem a disponibilidade de dados observados. Modelos estatísticos e dinâmicos são complementares, visto que avanços na previsão estatística estão associados a progresso acerca do conhecimento climático, o que induz a um desenvolvimento da previsão dinâmica (DOBLAS-REYES et al., 2013).

Os modelos dinâmicos são modelos matemáticos que representam as leis da física (KALNAY, 2003; YNOUE et al., 2017). Esses modelos podem ser globais ou regionais. Os Modelos Climáticos Globais (MCGs) simulam o comportamento atmosférico no globo e têm resolução horizontal da ordem de 100 km. Já os Modelos Climáticos Regionais (MCRs) simulam o comportamento atmosférico em uma área limitada, fornecendo informações mais detalhadas do clima, uma vez que a resolução horizontal é da ordem de 25-50 km. Porém, cabe ressaltar que, para isso, é necessária a aplicação da técnica de *downscaling* dinâmico, a qual utiliza as condições iniciais e de contorno fornecidas pelos MCGs para alimentar os MCRs (YNOUE et al., 2017; REBOITA et al., 2018). Devido às suas características, os modelos dinâmicos apresentam diferentes fontes de incertezas, que podem estar associadas às condições iniciais e de contorno, às aproximações nas equações e aos métodos numéricos de resolução dessas equações (BARRY e CHORLEY, 2010; REBOITA et al., 2012; YNOUE et al.,



2017; ROBERTSON e VITART, 2019). Além disso, deve-se ainda considerar os processos do ciclo hidrológico, os quais precisam de um período de ajuste e estabilização dentro do modelo, também conhecido como *spin-up time* (GIORGI e MEARNS, 1999).

Figura 2 - Diferenças entre modelos climáticos dinâmicos e estatísticos.



Fonte: Elaborado pelos autores (2021).

Observa-se ainda que os modelos numéricos possuem uma grande complexidade, uma vez que precisam representar os mecanismos de *feedback* entre os componentes do sistema climático (superfície, atmosfera, hidrosfera, criosfera e litosfera) e, por isso, são caros computacionalmente (GODDARD et al., 2001).

Os modelos estatísticos, também conhecidos como empíricos, utilizam uma ou mais variáveis observadas para estimar uma determinada variável atmosférica, como, por exemplo, a precipitação. Em geral, esses modelos utilizam menos recursos computacionais que os modelos dinâmicos, uma vez que não há a necessidade de resolver as equações que

descrevem os processos físicos do sistema climático. Contudo, necessitam de uma base de dados observados para gerar a previsão (GODDARD et al., 2001). A previsão climática com modelos estatísticos é baseada especialmente em técnicas de regressão linear, utilizando séries temporais de dados observados como preditores (como a TSM) para fornecer prognósticos de variáveis atmosféricas (MASON e BADDOUR, 2008). Outras metodologias utilizadas para a construção de modelos estatísticos são os métodos autorregressivos com média móvel e os modelos não lineares, como o de redes neurais (MALFATTI et al., 2018).

Os estudos sobre previsões climáticas divergem sobre a indicação de qual tipo de modelo tem melhor performance. Por exemplo, alguns estudos indicam que os modelos estatísticos se sobressaem quando comparados aos dinâmicos (e.g. LANDSEA e KNAFF, 2000; RAMÍREZ et al., 2008; DIRO et al., 2008), enquanto outros ressaltam a melhor performance dos modelos dinâmicos (e.g. WANG et al., 2009; COHEN e JONES, 2011; BARNSTON et al., 2012; KIRTMAN et al., 2014). Há, ainda, estudos que indicam que uma combinação das abordagens estatística e dinâmica melhora os resultados da previsão, reduzindo os erros (e.g. BLOCK e GODDARD, 2012; SCHEPEN et al., 2012; MADADGAR et al., 2016; NAJAFI e MORADKHANI, 2016; XU et al., 2018). Como já destacado por Goddard et al. (2001), a escolha do tipo de modelo (estatístico ou dinâmico) para a previsão climática sazonal depende do foco e recursos disponíveis para gerar a previsão, bem como de uma avaliação da performance do modelo na região de estudo. Porém, ressalta-se que com o avanço computacional, é possível melhorar a previsão sazonal. Em concordância com essa tendência, o *European Centre for Medium-Range Weather Forecasts* (ECMWF), junto a outros organizadores (*World Meteorological Organization*, *World Climate Research Programme*, *Subseasonal-to-Seasonal Project* e o *Swiss Data Science Center*), lançaram em 2021 um desafio/competição mundial para o aprimoramento das previsões sub-sazonais e sazonais de precipitação e TSM do seu melhor modelo dinâmico utilizando inteligência artificial (WCRP, 2021; WMO, 2021).

2.2. Fases da previsão climática

A previsão climática é composta basicamente por três etapas (YNOUE et al., 2017): (a) preparação das condições iniciais e pré-processamento dos dados que serão utilizados na integração das equações de previsão; (b) previsão (integração das equações); e (c) pós-



processamento (Figura 3). Entretanto, nem todas essas atividades são realizadas pelo responsável pela execução das simulações, como explica o texto a seguir.

Figura 3 - Representação esquemática das etapas envolvidas nas previsões climáticas.



Fonte: Elaborado pelos autores (2021).

Na primeira etapa, as condições iniciais correspondem aos dados observados da atmosfera, os quais são coletados a partir de diferentes instrumentos mediante sensoriamento remoto e medição *in situ*, bem como medições de navios e aviões. Aqui, ressalta-se que o sistema global de obtenção dos dados não possui medições *in situ* cobrindo todo o planeta e não se pode simplesmente assumir as estimativas de satélite como verdade absoluta, já que podem conter erros instrumentais e de algoritmo de organização dos dados (BARRY e CHORLEY, 2010; YNOUE et al., 2017; ROBERTSON e VITART, 2019). Por essa razão, a fim de espacializar os dados e amenizar possíveis erros, os dados são assimilados em programas computacionais a fim de transformá-los em um conjunto uniforme e consistente para ser fornecido como condições iniciais aos modelos de previsão.

Cabe ressaltar que, para os modelos estatísticos, a necessidade é de séries temporais extensas de variáveis atmosféricas e oceânicas, enquanto para os modelos dinâmicos são necessários dados atmosféricos observados (temperatura, umidade, entre outros) num dado instante, além das condições de contorno: TSM, vegetação e topografia. Nessa etapa, realiza-

se também a configuração das previsões: tempo de integração (dt em segundos), resolução horizontal (dx em metros), projeção cartográfica e definição dos esquemas de parametrização física que serão utilizados nos cálculos.

A segunda etapa consiste na previsão, na qual os modelos numéricos resolvem as equações para gerar um prognóstico. No caso dos modelos estatísticos, são equações empíricas, enquanto nos dinâmicos são as equações que descrevem o comportamento atmosférico e oceânico. Ainda considerando os modelos dinâmicos, nessa etapa, as equações são resolvidas em pontos de grade (mas também há modelos espectrais), sendo necessário informar o horizonte (tempo) da previsão, pois os modelos realizam a integração das equações até o período desejado. Além disso, as condições iniciais advindas dos dados do sistema global de observação são utilizadas apenas na primeira integração, pois nas seguintes a previsão realizada se torna a condição inicial para o passo seguinte de integração.

Por fim, na fase de pós-processamento, os meteorologistas utilizam os arquivos gerados nas previsões para a construção de mapas com as variáveis atmosféricas para facilitar a interpretação dos resultados, geração da previsão e redação dos boletins de prognósticos. A parte técnica envolvida na geração da previsão e elaboração desses boletins não é foco da discussão desse estudo, mas pode ser encontrada em Silva et al. (2021).

2.3. Previsão climática operacional no Brasil e no mundo

Em termos de globo, alguns centros meteorológicos se destacam na geração de previsões climáticas utilizando modelos dinâmicos, como a *National Oceanic and Atmospheric Administration* (NOAA) e o ECMWF. No caso da NOAA, podem-se citar os modelos *Climate Forecast System* (CFS; SAHA et al., 2010, 2014) e *North American Multi-Model Ensemble* (NMME; KIRTMAN et al., 2014), enquanto o ECMWF possui o modelo climático de mesmo nome, e está atualmente em operação o *System 5* (SEAS5; JOHNSON et al., 2019). Além disso, as previsões climáticas também podem ser geradas por meio de modelos estatísticos, conforme citado anteriormente, como ilustra o recente interesse do ECMWF em aprimorar suas previsões sub-sazonais a sazonais (S2S; WRCP, 2021; WMO, 2021).

Com relação ao Brasil, a previsão climática é executada operacionalmente pelo Centro de Previsão de Tempo e Estudos Climáticos do Instituto Nacional de Pesquisas Espaciais



(CPTEC/INPE), o qual gera as previsões com o *Brazilian Global Atmospheric Model* (BAM; FIGUEIROA et al., 2016), cujas saídas brutas estão disponíveis em: <http://ftp.cptec.inpe.br/clima/Modelos_Numericos/BAM1.2/>, e os resultados de forma gráfica em: <https://www.wmolc.org/seasonIndiFcstUI/plot_IndiFCST>. O Instituto Nacional de Meteorologia (INMET) também gera previsões sazonais de precipitação, porém utilizando modelos estatísticos baseados no modelo Autorregressivo Integrado a Médias Móveis (ARIMA) e no modelo de alisamento exponencial Holt-Winters (LÚCIO et al., 2010), com resultados disponíveis em: <<https://clima.inmet.gov.br/progp/0>>. De forma similar aos outros centros, a Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME) gera previsões sazonais, mas utilizando os modelos globais ECHAM46 (ROECKNER et al., 1996) e *Community Atmosphere Model* versão 3.1 (CAM3.1; COLLINS et al., 2004; 2006) e o modelo regional NCEP *Regional Spectral Model* versão 97 (RSM97; JUANG et al., 1997), cujos resultados estão disponíveis em: <http://www.funceme.br/dashboard/climate_forecast>. Por fim, há também uma cooperação entre o CPTEC, FUNCEME e INMET para gerar o prognóstico sazonal a partir de um modelo estatístico baseado em uma metodologia de regressão da média aritmética das previsões dos modelos que compõem o conjunto Multi-Modelo Nacional (CPTEC, 2021), com resultados disponíveis em: <<http://clima1.cptec.inpe.br/>>. Além desses centros, há uma parceria entre as instituições de ensino Universidade Federal de Itajubá (UNIFEI) e Universidade de São Paulo (USP) na validação das previsões climáticas sazonais para o Brasil a partir do *Regional Climate Model* (RegCM; GIORGI et al., 2012) a fim de torná-lo operacional (REBOITA et al., 2018). Nessa parceria, os pesquisadores desenvolvem atividades no Grupo de Estudos Climáticos (GrEC) da USP (www.grec.iag.usp.br) e promovem reuniões climáticas mensais abertas ao público para discussão de previsões climáticas sazonais baseadas nos modelos de diferentes centros de meteorologia.

3. DRIVERS DA VARIABILIDADE NATURAL DO CLIMA

O clima de um local corresponde à média dos eventos de tempo, mas isso não quer dizer que o valor climatológico se repete todos os anos. Algumas forçantes podem causar alterações no padrão de circulação atmosférica que, por sua vez, promovem a variabilidade do clima. Em termos técnicos, se diz que a variabilidade climática corresponde a um desvio

em relação ao valor médio esperado de uma dada variável meteorológica. Por exemplo, um verão em que a chuva exceda, em muito, o valor climatológico ou um verão que seja extremamente seco (chuva muito abaixo da média climatológica).

Duas das principais forçantes da variabilidade natural do clima em escala sazonal são a TSM e umidade do solo. Como essas forçantes possuem variações lentas (SCHNEIDER e DICKINSON, 1974; CHARNEY e SHUKLA, 1981; SHUKLA, 1984; BRANKOVIĆ et al., 1994; DIRMEYER, 2011), isso torna possível a realização da previsão climática sazonal. Na sequência, é explicada a influência da umidade do solo e da TSM na variabilidade do clima.

A umidade do solo representa um processo de acoplamento entre a superfície e a atmosfera. Em outras palavras, as variações na umidade do solo modificam o balanço de energia da superfície (afetando o desenvolvimento da camada limite atmosférica) e o balanço hídrico, por meio da evapotranspiração e da precipitação (BETTS et al., 1996; PIELKE et al., 1999; FU et al., 2004; KOSTER et al., 2004; DIRMEYER, 2011; SANTANELLO JÚNIOR et al., 2011; NICHOLSON, 2015; ESIT et al., 2021). A umidade do solo afeta a partição da radiação líquida entre os fluxos de calor sensível (energia usada para aquecer o ar) e latente (energia necessária para a evaporação) influenciando a temperatura do ar (MUELLER e SENEVIRATNE, 2012). Com relação à previsão sazonal, a umidade do solo tem maior impacto nas áreas de transição entre climas secos e úmidos, onde o acoplamento entre a umidade do solo e a evapotranspiração é esperado ser mais intenso para afetar o clima (DIRMEYER et al., 2009; NICHOLSON, 2015), bem como em regiões onde há memória da umidade do solo e forte acoplamento solo-atmosfera (GUO et al., 2011, 2012). Teodoro e Reboita (2019) analisaram a relação entre a precipitação e a umidade do solo, em duas camadas da superfície com profundidades distintas, na AS, no período de 2009 a 2018. Sazonalmente, o padrão espacial da precipitação e da umidade do solo em ambas as camadas é muito similar. Em escala mensal, a umidade na camada de solo mais superficial tem sua variabilidade temporal similar à da precipitação, enquanto a mais profunda tem uma resposta com atraso de um mês em relação à precipitação (por exemplo, se a chuva reduz num dado mês, o déficit de água no solo será no mês posterior).

As anomalias de TSM causam perturbações na atmosfera que se propagam na forma de ondas. Essas ondas, por sua vez, geram padrões anômalos de pressão na atmosfera, afetando a localização, intensidade e/ou frequência dos sistemas atmosféricos atuantes numa

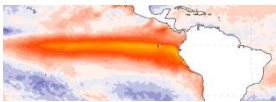
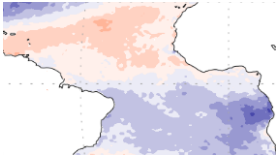
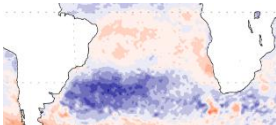


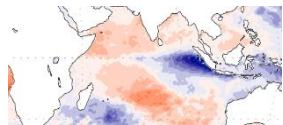
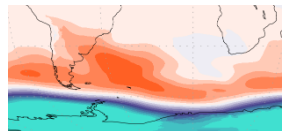
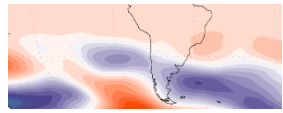
dada região. Como consequência, têm-se alterações no valor médio esperado das variáveis de precipitação, temperatura do ar e outras. Os eventos que ocorrem num dado local do globo e afetam o clima de regiões remotas constituem os padrões de teleconexão (LIU e ALEXANDER, 2007; FELDSTEIN e FRANZKE, 2017; REBOITA et al., 2021). Vários dos padrões de teleconexões ocorrem concomitantemente, o que gera um desafio para a previsão climática, uma vez que o impacto deles pode resultar em uma resposta combinada de forma a ampliar um dado efeito ou oposta, enfraquecendo e/ou anulando os impactos esperados (REBOITA et al., 2021). Outro aspecto importante que deve ser ressaltado consiste na variabilidade temporal dos oceanos ser menor do que a da atmosfera em virtude dos diferentes valores de calor específico, de tal forma que o impacto da TSM na atmosfera tem uma resposta defasada (TROCCOLI, 2010).

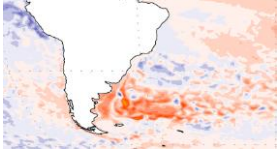
No **Quadro 1** são apresentados alguns dos principais padrões de teleconexão que afetam a AS e os seus impactos na precipitação. A seleção dos eventos ilustrados no quadro baseou-se no estudo de Reboita et al. (2021), o qual apresenta uma descrição extensa e detalhada dos impactos de diferentes padrões de teleconexão sobre a temperatura e precipitação na AS, considerando períodos neutros em termos do fenômeno El Niño Oscilação Sul (ENOS). Neste estudo também são fornecidas as séries temporais sazonais de índices de monitoramento de sete padrões de teleconexão para o período de 1979 a 2020, fornecidos por diferentes centros climáticos. Dessa forma, os eventos exemplificados no **Quadro 1** basearam-se nas maiores anomalias positivas obtidas para cada índice, como apresentado em Reboita et al. (2021). Por exemplo, para o Dipolo do Atlântico Subtropical, a maior anomalia positiva ocorreu em fevereiro de 1985, com valor de 1,76 (Reboita et al., 2021). Portanto, os eventos ilustrados no **Quadro 1** correspondem a casos extremos de anomalia positiva dos padrões referidos ocorridos nas últimas décadas.

Por fim, menciona-se que os autores supracitados elaboraram um Atlas de diversos índices de teleconexão que se encontra disponível em <<https://meteorologia.unifei.edu.br/teleconexoes/>>. Neste mesmo sítio, é provido o monitoramento dos índices para auxiliar as práticas de previsão de clima (SOUZA e REBOITA, 2021).

Quadro 1 - Principais padrões de teleconexão que afetam o clima sazonal da América do Sul

Padrão de teleconexão	Definição	Índice de Monitoramento	Impacto na Precipitação
<p>El Niño-Oscilação Sul</p>	<p>Anomalias de TSM no Pacífico Equatorial (setores central e leste)</p> <p>Dez de 1997</p> 	<p>Índice de Oscilação Sul (IOS); Índices Niño 1+2, 3, 3.4 e 4, correspondentes às regiões de monitoramento; <i>Trans-Niño Index</i> (TNI); <i>Oceanic Niño Index</i> (ONI); <i>Multivariate ENSO index</i> (MEI); <i>Bivariate ENSO Time Series</i> (BEST)</p> <p>Fase positiva: anomalias positivas de TSM na região do Pacífico tropical central e leste.</p>	<p>Fase positiva:</p> <ul style="list-style-type: none"> - Redução de precipitação no norte e nordeste do Brasil; - Aumento de precipitação no sul do Brasil. <p>Fase negativa:</p> <ul style="list-style-type: none"> - Aumento de precipitação no norte e nordeste do Brasil; - Redução de precipitação no sul do Brasil.
<p>Anomalias de TSM no Atlântico Tropical</p>	<p>Anomalias de TSM no Atlântico Tropical Norte (5°N-25°N, 15°W-55°W) e Sul (20°S-0°, 30°W-10°E)</p> <p>Mar de 1981</p> 	<p><i>Tropical Northern Atlantic Index</i> (TNA); <i>Tropical Southern Atlantic Index</i> (TSA)</p> <p>TNA e TSA positivas correspondem a anomalias de TSM acima do valor climatológico.</p>	<p>Fase positiva da TSA:</p> <ul style="list-style-type: none"> - Aumento de precipitação no setor litorâneo do Nordeste <p>Fase negativa:</p> <ul style="list-style-type: none"> - Redução de precipitação no setor litorâneo do Nordeste
<p>Dipolo do Atlântico Sul Subtropical</p>	<p>Anomalias de TSM com sinais opostos entre os setores tropical e subtropical do oceano Atlântico Sul Subtropical</p> <p>Fev de 1985</p> 	<p><i>South Atlantic Ocean Dipole Index</i> (SAODI); <i>South Atlantic Subtropical Dipole Index</i> (SASDI)</p> <p>Fase positiva possui anomalias de TSM positivas no setor tropical e negativas no setor subtropical do Atlântico Sul.</p>	<p>Fase positiva:</p> <ul style="list-style-type: none"> - Aumento de precipitação no litoral do Nordeste e sul da AS; - Redução de precipitação na região Sudeste. <p>Fase negativa:</p> <ul style="list-style-type: none"> - Aumento de precipitação na região Sudeste; - Redução de precipitação no litoral do Nordeste e sul da AS.

<p>Dipolo do Oceano Índico</p>	<p>Anomalias de TSM com sinais opostos entre os setores leste (10°S-0°, 90°E-110°E) e oeste (10°N-10°S, 50°E-70°E) do oceano Índico Tropical</p> <p>Nov de 1997</p> 	<p><i>Dipole Mode Index West</i> (DMI_W); <i>Dipole Mode Index East</i> (DMI_E)</p> <p>Fase positiva é caracterizada por anomalias positivas de TSM no setor ocidental e negativas no setor oriental do oceano Índico.</p>	<p>Fase positiva:</p> <ul style="list-style-type: none"> - Aumento de precipitação no sudeste e noroeste da AS e sul do Brasil; - Redução de precipitação nas regiões Norte e Nordeste. <p>Fase negativa:</p> <ul style="list-style-type: none"> - Aumento de precipitação nas regiões Sudeste e Centro-Oeste; - Redução de precipitação no sudeste da AS e sul do Brasil.
<p>Modo Anular Sul</p>	<p>Anomalias de altura geopotencial em 700 hPA com sinais opostos entre as cercanias da Antártica e as latitudes próximas a 45°S, calculado através da técnica de Análise de Componentes Principais, sendo os valores obtidos a partir da primeira componente principal.</p> <p>Mai de 1989</p> 	<p><i>Antarctic Oscillation</i> (AAO)</p> <p>Fase positiva: anomalias negativas de altura geopotencial ao redor da Antártica e positiva a cerca de 45°S.</p>	<p>Fase positiva:</p> <ul style="list-style-type: none"> - Aumento de precipitação no sudeste do Brasil; - Redução de precipitação no sul do Brasil e sudeste da AS. <p>Fase negativa:</p> <ul style="list-style-type: none"> - Aumento de precipitação no sul do Brasil e sudeste da AS; - Redução de precipitação no sudeste do Brasil.
<p>Padrão Pacífico-América do Sul</p>	<p>Padrão de onda de número 3 e assemelha-se a um arco entre o Pacífico tropical e o oceano Atlântico.</p> <p>Dez de 1997</p> 	<p><i>Pacific-South American Pattern</i> (PSA)</p> <p>Na fase positiva, predomina-se a anomalia de circulação ciclônica no sul da AS e anticiclônica entre o sudeste do Brasil e Atlântico.</p>	<p>Fase positiva:</p> <ul style="list-style-type: none"> - Aumento de precipitação no sul do Brasil e na região da Zona de Convergência do Atlântico Sul; - Redução de precipitação no nordeste do Brasil. <p>Fase negativa:</p> <ul style="list-style-type: none"> - Redução de precipitação no sul do Brasil.
<p>Anomalias de TSM na costa do Uruguai e</p>	<p>Anomalias de TSM no Atlântico na região costeira entre o Uruguai e o sul do Brasil</p>	<p>Índice de TSM na RG2 (ITSMRG2)</p>	<p>Fase positiva:</p> <ul style="list-style-type: none"> - Aumento de precipitação no sudeste da AS e sul do Brasil;

do sul do Brasil	<p>Mai de 2021</p> 	Fase positiva corresponde a valores acima da média climatológica.	<p>Fase negativa:</p> <p>- Redução de precipitação no sudeste da AS e sul do Brasil.</p>
------------------	--	---	---

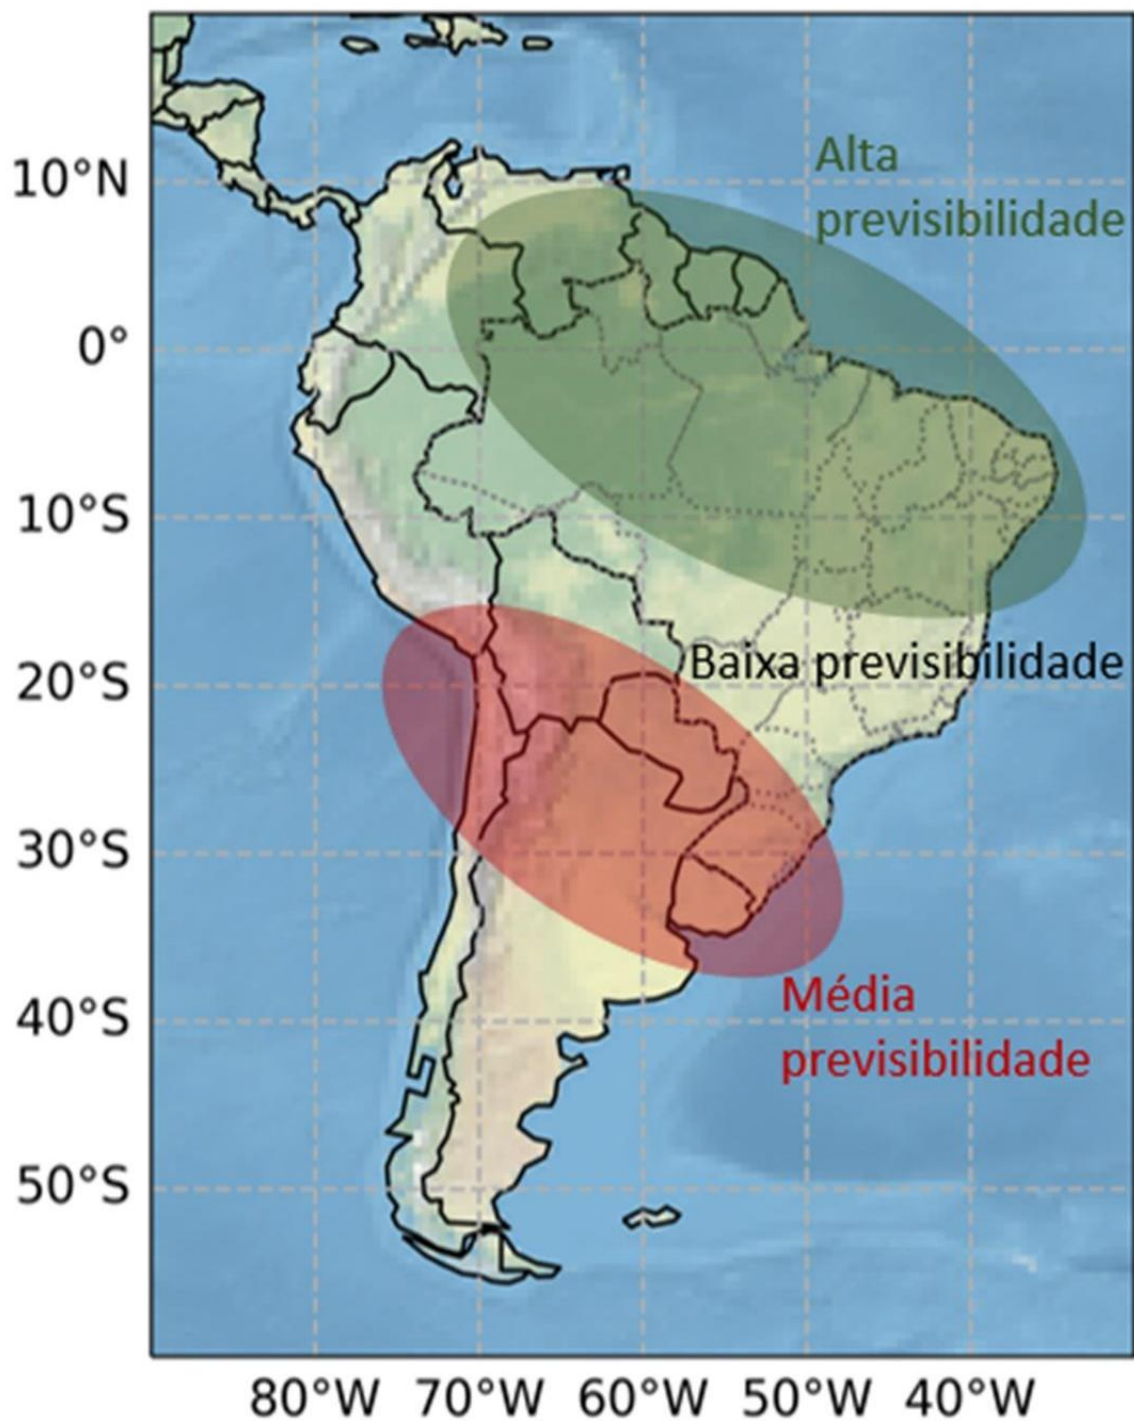
Em Cavalcanti e Ferreira (2021) também é apresentada uma discussão dos impactos de vários padrões de teleconexão no clima do Brasil. Já Torres et al. (2021) fazem uma análise da correlação entre as séries temporais com defasagem (de 1 a 7 meses) de índices relacionados aos diferentes padrões de teleconexão com a precipitação no país para o trimestre DJF, mas sem excluir a influência do ENOS, o que difere de Reboita et al. (2021). De acordo com os autores, alguns padrões de teleconexão causam maior variabilidade do clima do que outros nas diferentes regiões do Brasil.

Na região Sul, domina a variabilidade associada à influência do ENOS (resultado obtido quando a série temporal do índice é defasada de 1 a 7 meses, ou seja, lags 1 a 7), do Dipolo do Oceano Índico (lags 1 a 3) e das anomalias de TSM na costa do Uruguai e do sul do Brasil (lags 1 a 3) (TORRES et al., 2021).

A região Sudeste é mais sensível ao Dipolo do Atlântico Sul Subtropical (lags 1 a 7) e ao Modo Anular Sul (lag 1); a região Nordeste, ao Dipolo do Atlântico Sul Subtropical (lags 3 a 7) e às anomalias de TSM na costa do Uruguai e do sul do Brasil (lag 1); a região Norte, ao ENOS (lags 1 a 6) e às anomalias de TSM nos setores norte e sul do Atlântico Tropical (lags 4 a 7) e ao Dipolo do Atlântico Sul Subtropical (lags 1 a 7), bem como ao Dipolo do Oceano Índico (lags 1 a 6), ao Padrão Pacífico-América do Sul (lags 1 a 5), ao Modo Anular Sul (lag 3), e às anomalias de TSM na costa do Uruguai e do sul do Brasil (lags 1 a 7); e a região Centro-Oeste, às anomalias de TSM na costa do Uruguai e do sul do Brasil (lags 1 a 7) (TORRES et al., 2021).

É importante ressaltar que as correlações observadas por Torres et al. (2021) são fracas ou moderadas, com exceção dos resultados obtido para o ENOS e o Dipolo do Oceano Índico, que se mostram mais intensas e persistentes mesmo com o atraso das séries temporais dos índices. Com base nesse e em estudos prévios (MARENGO et al., 2003; COELHO et al., 2012; SAMPAIO e SILVA DIAS, 2014), tem-se que as regiões Norte e Nordeste possuem boa previsibilidade sazonal, a Sul, média e as regiões Centro-Oeste e Sudeste, baixa (**Figura 4**).

Figura 4 - Previsibilidade climática para a América do Sul.



Fonte: Modificado de Ynoue et al. (2017).

4. CONSIDERAÇÕES FINAIS

Este estudo apresentou de forma didática os *drivers* (forçantes) da variabilidade natural do clima com foco na América do Sul e Brasil. É mostrado que as anomalias de TSM causam alterações na circulação atmosférica que impactam na frequência, intensidade e duração dos sistemas atmosféricos e, por conseguinte, afetam a precipitação e temperatura das diferentes regiões do globo. Diversos estudos identificaram quais regiões respondem melhor à influência de cada padrão de teleconexão, pois isso auxilia na previsão climática sazonal. Por exemplo, na ocorrência da fase quente do ENOS, sabe-se que há excesso de precipitação no sul do Brasil, logo, se os modelos climáticos preveem anomalias positivas de TSM no Pacífico tropical central e leste, isso é um indicativo de que ocorrerá uma mudança no clima da região Sul, levando a mais chuva. Quanto ao impacto da umidade do solo, isso ainda é um tema menos explorado, que carece de estudos adicionais.

Destaca-se que, nas últimas décadas, a previsão climática sazonal evoluiu devido ao progresso de diversas áreas científicas associadas a ela, como o avanço do conhecimento acerca dos componentes do sistema climático, aumento da capacidade computacional, desenvolvimento dos sistemas de observações e técnicas de assimilação de dados, aumento da resolução dos modelos. No entanto, a previsão climática em todas suas escalas temporais, está em constante evolução e muitas questões necessitam de mais estudos. Por exemplo, a redução dos erros dos modelos está diretamente ligada ao desenvolvimento de modelos mais acurados (como os modelos acoplados oceano-atmosfera), o que por sua vez está relacionado ao avanço do conhecimento dos processos e mecanismos do sistema climático, visto que é difícil modelar o que não é compreendido. Nesse contexto, a melhoria dos sistemas de medições e assimilação de dados, bem como aumento da capacidade computacional e resolução dos modelos, são fatores que contribuem na construção de simulações climáticas mais confiáveis. Além disso, ressalta-se a necessidade de mais estudos sobre os mecanismos oceânicos e sua variabilidade a longo prazo.

Por fim, reitera-se que a evolução da previsão climática em todos seus horizontes temporais beneficia diversos setores da sociedade, pois auxilia no planejamento e tomada de decisão, a fim de reduzir eventuais efeitos negativos advindos do clima. Neste quadro, o desenvolvimento da previsão climática no Brasil mostra-se promissor, dado que diversas



universidades e centros de pesquisa desenvolvem estudos de alta qualidade, cujos benefícios são ilimitados para um país muitíssimo dependente das condições climáticas.

AGRADECIMENTOS

Os autores agradecem ao CNPq, CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil - Código de Financiamento 001), FAPEMIG e ENERGISA pelo suporte financeiro.

REFERÊNCIAS

ARMSTRONG, B. G.; CHALABI, Z.; FENN, B. *et al.* Association of mortality with high temperatures in a temperate climate: England and Wales. **Journal of Epidemiology & Community Health**, v. 65, n. 4, p. 340-345, 2010.

BALDONI, T. C.; SILVA, P. L. L. S.; SOUZA, C. A. TEODORO, T. A.; KUKI, C. A. C.; REBOITA, M. S. Comparação da Precipitação na América do Sul Obtida de Diferentes Bases de Dados. In: **VIII Seminário de Recursos Naturais**, 2021, Itajubá. SRN, 2021.

BARNSTON, A. G.; TIPPETT, M. K.; L'HEUREUX, M. L. *et al.* 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.

BARRY, R. G.; CHORLEY, R. J. **Atmosphere, weather and climate**. 9ª. ed. New York: Routledge, 2010.

BETTS, A. K.; BALL, J. H.; BELJAARS, A. C. M. *et al.* The land surface-atmosphere interaction: A review based on observational and global modeling perspectives. **Journal of Geophysical Research: Atmospheres**, v. 101, p. 7209-7225, 1996.

BLOCK, P.; GODDARD, L. Statistical and dynamical climate predictions to guide water resources in Ethiopia. **Journal of Water Resources Planning and Management**, v. 138, p. 287-298, 2012.

BRANKOVIĆ, C.; PALMER, T. N.; FERRANTI, L. Predictability of seasonal atmospheric variations. **Journal of Climate**, v. 7, p. 217-237, 1994.

BRENDEL, C. E.; DYMOND, R. L.; AGUILAR, M. F. Integration of quantitative precipitation forecasts with real-time hydrology and hydraulics modeling towards probabilistic forecasting of urban flooding. **Environmental Modelling & Software**, v. 134, p. 104864, 2020.

CAI, W.; SANTOSO, A.; COLLINS, M. *et al.* Changing El Niño-Southern Oscillation in a warming climate. **Nature Reviews Earth & Environment**, v. 2, p. 628-644, 2021.

CAVALCANTI, I. F. A.; FERREIRA, N. J. **Clima das regiões brasileiras e variabilidade climática**. São Paulo: Oficina de Textos, 2021.

CHARNEY, J. G.; SHUKLA, J. Predictability of monsoons. In LIDTHILL, J.; PEARCE, R. (eds) **Monsoon dynamics**. Cambridge: Cambridge University Press, 1981. 99-110p.

COELHO, C. A. S.; CAVALCANTI, I. F. A.; COSTA, S. M. S. *et al.* Climate diagnostics of three major drought events in the Amazon and illustrations of their seasonal precipitation predictions. **Meteorological Applications**, v. 19, p. 237-255, 2012.

COHEN, J.; JONES, J. A new index for more accurate winter predictions. **Geophysical Research Letters**, v. 38, p. L21701, 2011.

COLLINS, W. D.; RASCH, P. J.; BOVILLE, B. A. *et al.* **Description of the NCAR Community Atmosphere Model (CAM3.0)**. NCAR Technical Note NCAR/TN-464+ STR. Boulder, 2004. Disponível em: < <https://www.cesm.ucar.edu/models/atm-cam/docs/description/description.pdf> >. Acesso em: 20 set. 2021

COLLINS, W. D.; RASCH, P. J.; BOVILLE, B. A. *et al.* The Formulation and Atmospheric Simulation of the Community Atmosphere Model Version 3 (CAM3). **Journal of Climate**, v. 19, p. 2144-2161, 2006.

CPTEC. **Previsão climática sazonal**. CPTEC. [Cachoeira Paulista], 01 out. 2021. Disponível em: <http://clima1.cptec.inpe.br/~rclima1/pdf_notatecnica/Nota_Tecnica.pdf>. Acesso em: 17 set. 2021.

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.

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.; WANG, Z.; MBUH, M. J.; NORTON, H. E. Intensified land surface control on boundary layer growth in a changing climate. **Geophysical Research Letters**, v. 41, p. 1290-1294, 2009.

DIRMEYER, P. A. The terrestrial segment of soil moisture–climate coupling. **Geophysical Research Letters**, v. 38, p. L16702, 2011.

DIRO, G. T.; BLACK, E.; GRIMES, D. I. F. Seasonal forecasting of Ethiopian spring rains. **Meteorological Applications**, v. 15, p. 73-83, 2008.

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.

ESIT, M.; KUMAR, S.; PANDEY, A. *et al.* Seasonal to multi-year soil moisture drought forecasting. *Climate and Atmospheric Science*, v. 4, p. 1-8, 2021.



FELDSTEIN, S. B.; FRANZKE, C. L. E. Atmospheric teleconnection patterns. In FRANZKE, C. L. E.; O'KANE, T. J. (eds) **Nonlinear and stochastic climate dynamics**. Cambridge: Cambridge University Press. pp. 54-104, 2017.

FIGUEIROA, S. N.; BONATTI, J. P.; KUBOTA, P. Y. *et al.* The Brazilian Global Atmospheric Model (BAM): Performance for Tropical Rainfall Forecasting and Sensitivity to Convective Scheme and Horizontal Resolution. **Weather and Forecasting**, v. 31, n.5, p. 1547-1572, 2016.

FU, R.; LI, W. The influence of the land surface on the transition from dry to wet season in Amazonia. **Theoretical and Applied Climatology**, v. 78, p. 97-110, 2004.

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

GIORGI, F.; COPPOLA, E.; SOLMON, F. *et al.* RegCM4: Model description and preliminary tests over multiple CORDEX domains. **Climate Research**, v. 52, p. 7-29, 2012.

GODDARD, L.; MASON, S. J.; ZEBIAK, S. E. *et al.* Current approaches to seasonal to interannual climate predictions. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, v. 21, p. 1111-1152, 2001.

GUO, Z.; DIRMEYER, P. A.; DELSOLE, T. Land surface impacts on subseasonal and seasonal predictability. **Geophysical Research Letters**, v. 38, p. L24812, 2011.

GUO, Z.; DIRMEYER, P. A.; DELSOLE, T.; KOSTER, R. D. Rebound in atmospheric predictability and the role of the land surface. **Journal of Climate**, v. 25, p. 4744-4749, 2012.

GUSTIN, M.; McLEOD, R. S.; LOMAS, K. J. Forecasting indoor temperatures during heat waves using time series models. **Building and Environment**, v. 143, p. 727-739, 2018.

JAMAL, A.; LINKER, R.; HOUSH, M. Comparison of Various Stochastic Approaches for Irrigation Scheduling Using Seasonal Climate Forecasts. **Journal of Water Resources Planning and Management**, v. 144, n. 7, p. 04018028, 2018.

JOHNSON, S. J.; STOCKDALE, T. N.; FERRANTI, L. *et al.* SEAS5: the new ECMWF seasonal forecast system. **Geoscientific Model Development**, v. 12, p. 1087-1117, 2019.

JUANG, H. M. H.; HONG, S. Y.; KANAMITSU, M. The NCEP Regional Spectral Model: An update. **Bulletin of the American Meteorological Society**, v. 78, p. 2125-2144, 1997.

KALNAY, E. **Atmospheric modeling, data assimilation and predictability**. Cambridge: Cambridge University Press, 2003.

KIRTMAN, B. P.; MIN, D.; INFANTI, J. M. *et al.* The North American Multi-Model Ensemble (NMME): Phase-1 seasonal to interannual prediction, phase-2 toward developing intra-seasonal prediction. **Bulletin of the American Meteorological Society**, v. 95, n.4, p. 585-601, 2014.

KOSTER, R. D.; DIRMEYER, P. A.; GUO, Z. *et al.* Regions of strong coupling between soil moisture and precipitation. **Science**, v. 305, p. 1138-1140, 2004.

KUKI, C. A. C. **Metodologia para previsão de preço de energia considerando incertezas de vazões**. 2009. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Itajubá, Itajubá, 2020.

KUKI, C. A. C.; TORRES, F. L. R.; DE FARIA, V. A. D. *et al.* Estratégias de previsão de vazão de curto prazo: Um estudo de caso nas bacias do rio Grande e rio Paranaíba. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 23., 2020, on-line. **Anais [...]**. 2020.

LANDSEA, C.; KNAFF, A. How much skill was there in forecasting the very strong 1997-1998 El Niño? **Bulletin of American Meteorological Society**, v. 8, p. 2107–2119, 2000.

LIU, Z; ALEXANDER, M. Atmospheric bridge, oceanic tunnel, and global climatic teleconnections. **Reviews of Geophysics**, v. 45, n. 2, p. 27-40, 2007.

LORENZ, E. N. The predictability of hydrodynamic flow. **Transactions of the New York Academy of Sciences**, v. 25, p. 409-435, 1963.

LORENZ, E. N. Predictability: does the flap of a butterfly's wing in Brazil set off a tornado in Texas? In: Environmental Sciences, New Approaches to Global Weather: GARP, 1972, Boston. **Anais [...]**. 1972.

LÚCIO, P. S.; SILVA, F. D. S.; FORTES, L. T. G. *et al.* Um modelo estocástico combinado de previsão sazonal para a precipitação no Brasil. **Revista Brasileira de Meteorologia**, v. 25, n. 1, p. 70-87, 2010.

MADADGAR, S.; AGHAKOUCHAK, A.; SHUKLA, S. *et al.* A hybrid statistical-dynamical framework for meteorological drought prediction: Application to the southwestern United States. **Water Resources Research**, v. 52, p. 5095- 5110, 2016.

MALFATTI, M. G. L.; CARDOSO, A. O.; HAMBURGUER, D. S. Modelo empírico linear para previsão de vazão de rios na usina hidrelétrica de Itaipu–Bacia do Rio Paraná. **Revista Brasileira de Meteorologia**, v. 33, p. 257-268, 2018.

MARENGO, J. A.; CAVALCANTI, I. F. A.; SATYAMURTY, P. *et al.* Assessment of regional seasonal rainfall predictability using the CPTEC/COLA atmospheric GCM. **Climate Dynamics**, v. 21, p. 459-475, 2003.

MARTINS, M. A.; TOMASELLA, J.; RODRIGUEZ, D. A. *et al.* Improving drought management in the Brazilian semiarid through crop forecasting. **Agricultural Systems**, v. 160, p. 21-30, 2018.

MASON, S. J.; BADDOUR, O. Statistical modelling. In: TROCOLLI, A.; HARRISON, M.; ANDERSON, D. L. T.; MASON, S. J. (eds) **Seasonal climate: forecasting and managing risk**. Dordrecht: Springer, 2008.

MEEHL, G. A.; RICHTER, J. H.; TENG, H. *et al.* Initialized Earth System prediction from subseasonal to decadal timescales. **Nature Reviews Earth & Environment**, v. 2, p. 340–357, 2021.

MUELLER, B.; SENEVIRATNE, S. I. Hot days induced by precipitation deficits at the global scale. **Proceedings of the National Academy of Sciences**, v. 109, p. 12398-12403, 2012.



NAJAFI, M. R.; MORADKHANI, H. Ensemble combination of seasonal streamflow forecasts. **Journal of Hydrologic Engineering**, v. 21, p. 04015043, 2016.

NICHOLSON, S. E. Evolution and current state of our understanding of the role played in the climate system by land surface processes in semi-arid regions. **Global and Planetary Change**, v. 133, p. 201-222, 2015.

NOBRE, P.; SHUKLA, J. Variations of sea surface temperature, wind stress, and rainfall over the tropical Atlantic and South America. **Journal of Climate**, v. 9, p. 2464-2479, 1996.

PIELKE, R. A.; LISTON, G. E.; LU, L. Climate Prediction as an initial value problem. **Journal of Geophysical Research: Atmospheres**, v. 104, p. 19463-19479, 1999.

RAMÍREZ, M. C. V.; DE CAMPOS VELHO, H. F.; FERREIRA, N. J. Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region. **Journal of Hydrology**, v. 301, p. 146-162, 2008.

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.; 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.; AMBRIZZI, T.; CRESPO, N. M. *et al.* Impacts of teleconnection patterns on South America climate: a review. **Annals of the New York Academy of Sciences**, 2021.

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

RODRIGUEZ, D.; DE VOIL, P.; HUDSON, D. *et al.* Predicting optimum crop designs using crop models and seasonal climate forecasts. **Scientific Reports**, v. 8, p. 2231, 2018.

ROECKNER, E.; ARPE, K.; BENGTTSSON, L. *et al.* **The atmospheric general circulation model ECHAM-4: Model description and simulation of present-day climate**. Max-Planck-Institut für Meteorologie. Report nº 218. Hamburg. 1996. Disponível em: <<http://centaur.reading.ac.uk/31813/>>. Acesso em: 17 set. 2021.

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

SAHA, S.; MOORTHY, S.; WU, X. *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. D. Evolução dos modelos climáticos e de previsão de tempo e clima. **Revista USP**, n. 103, p. 41-54, 2014.

SANTANELLO JÚNIOR, J. A.; PETERS-LIDARD, C.; KUMAR, S. V. Diagnosing the sensitivity of local land-atmosphere coupling via the soil moisture-boundary layer interaction. **Journal of Hydrometeorology**, v. 12, p. 766-786, 2011.

SCHEPEN, A.; WANG, Q. J.; ROBERTSON, D. E. Combining the strengths of statistical and dynamical modeling approaches for forecasting Australian seasonal rainfall. **Journal of Geophysical Research**, v. 117, p. D20107, 2012.

SCHNEIDER, S. H.; DICKINSON, R. E. Climate modeling. **Reviews of Geophysics and Space Physics**, v. 12, p. 447-493, 1974.

SHUKLA, J. Dynamical predictability of monthly means. **Journal of the Atmospheric Sciences**, v. 38, p. 2547-2572, 1981.

SHUKLA, J. Predictability of time averages. Part II: The influence of the boundary forcing. In: BURRIDGE, D. M.; KÄLLÉN, E. (eds) **Problems and prospects in long and medium range weather forecasting**. New-York: Springer, p. 155-206, 1984.

SHUKLA, J.; KINTER, J. L. Predictability of seasonal climate variations: a pedagogical review. In PALMER, T.; HAGEDORN, R. (eds) **Predictability of Weather and Climate**. Cambridge: Cambridge University Press, 2006. 306-341p.

SIKDER, M. S.; AHMAD, S.; HOSSAIN, F. *et al.* Case study: Rapid urban inundation forecasting technique based on quantitative precipitation forecast for Houston and Harris County flood control district. **Journal of Hydrologic Engineering**, v. 24, n. 8, p. 05019017, 2019.

SILVA, G. M. C.; GOZZO, L. F.; REBOITA, M. S. Etapas de uma previsão climática sazonal. **Terrae Didática**, v. 17, n. 0, p. e021026, 2021.

SILVA, L. F.; REBOITA, M. S.; ALVES, M. A. Notificações de casos de dengue em Minas Gerais e sua relação com variáveis ambientais e sócioeconômicas. **Revista Brasileira de Geografia Física**, v. 12, n. 1, p. 226-238, 2019.

SIMMONS, A. J.; HOLLINGSWORTH, A. Some aspects of the improvement in skill of numerical weather prediction. **Quarterly Journal of the Royal Meteorological Society: A journal of the atmospheric sciences, applied meteorology and physical oceanography**, v. 128, p. 647-677, 2002.

SOUZA, C. A.; REBOITA, M. S. Ferramenta para o monitoramento dos padrões de teleconexão na América do Sul. **Terrae Didática**, v. 17, p. e02109, 2021.

TEODORO, T. A.; REBOITA, M. S. Análise climatológica da variabilidade espaço-temporal da umidade do solo sobre a América do Sul. In: VIII Simpósio Internacional de Climatologia, 2019, Belém-PA. **Anais [...]**. 2019.

THORND AHL, S.; NIELSEN, J. E.; JENSEN, D. G. Urban pluvial flood prediction: a case study evaluating radar rainfall nowcasts and numerical weather prediction models as model inputs. **Water Science and Technology**, v. 74, n. 11, p. 2599-2610, 2016.

TROCCOLI, A. Seasonal climate forecasting. In: TROCCOLI, A.; HARRISON, M.; ANDERSON, D. L.; MASON, S. J. (eds) **Seasonal climate: forecasting and managing risk**, v. 82. Gallipoli: Springer Science & Business Media, 2010.



TORRALBA, V.; DOBLAS-REYES, F. J.; McLEOD, D. *et al.* Seasonal climate prediction: A new source of information for the management of wind energy resources. **Journal of Applied Meteorology and Climatology**, v. 56, n.5, p. 1231-1247, 2017.

TORRES, F. L. R.; KUKI, C. A. C.; REBOITA, M. S.; LIMA, L. M. M.; LIMA, J. W. M.; QUEIROZ, A. R. Improving seasonal precipitation forecast in Brazil using machine learning techniques and climate indices. Submetido. 2021.

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

WANG, B.; LEE, J. Y.; KANG, I. S. *et al.* Advance and prospectus of seasonal prediction: assessment of the APCC/ClipAS 14-model ensemble retrospective seasonal prediction (1980–2004). **Climate Dynamics**, v. 33, p. 93-117, 2009.

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

WMO. **Guide to climatological practices**. Geneva: World Meteorological Organization, 2018.

WMO. **Challenge to improve Sub-seasonal to Seasonal predictions using Artificial Intelligence**. WMO, 04 mai. 2021. Disponível em: <https://s2s-ai-challenge.github.io/?fbclid=IwAR3bue3YddZY8EAmwtPB1JpAv6sV-2qUu3vqGYNPZ4snAGz2xxGi_hGyJRk>. Acesso em: 23 set. 2021.

WCRP. **Prize Challenge to improve Sub-seasonal to Seasonal predictions using Artificial Intelligence**. WCRP, 2021. Disponível em: <<https://www.wcrp-climate.org/news/wcrp-news/1681-s2s-prize-challenge>>. Acesso em: 23 set. 2021.

XU, L.; CHEN, N.; ZHANG, X. A comparison of large-scale climate signals and the North American Multi-Model Ensemble (NMME) for drought prediction in China. **Journal of Hydrology**, v. 557, p. 378-390, 2018.

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