



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

JOÃO MARIA DE ANDRADE

**ESTUDOS HIDROLÓGICOS COM BASE EM GRANDES AMOSTRAS E
DEEP LEARNING: contribuições para aplicações em bacias hidrográficas no Brasil**

Recife

2024

JOÃO MARIA DE ANDRADE

**ESTUDOS HIDROLÓGICOS COM BASE EM GRANDES AMOSTRAS E
DEEP LEARNING: contribuições para aplicações em bacias hidrográficas no Brasil**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Doutor em Engenharia Civil.

Área de concentração: Tecnologia Ambiental e Recursos Hídricos.

Orientadora: Profa. Dra. Suzana Maria Gico Lima Montenegro.

Coorientador: Prof. Dr. Alfredo Ribeiro Neto.

Recife

2024

Catálogo na fonte
Bibliotecária Margareth Malta, CRB-4 / 1198

A554e	Andrade, João Maria de. Estudos hidrológicos com base em grandes amostras e <i>deep learning</i>: contribuições para aplicações em bacias hidrográficas no Brasil / João Maria de Andrade. – 2024. 161 f.: il., figs., tabs., abrev. e sigl. Orientadora: Profa. Dra. Suzana Maria Gico Lima Montenegro. Coorientador: Prof. Dr. Alfredo Ribeiro Neto. Tese (Doutorado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Civil, 2024. Inclui Referências e Apêndices. 1. Engenharia Civil. 2. LSTM. 3. Produto de precipitação de satélite. 4. Séries hidrológicas. 5. Modelagem chuva-vazão. I. Montenegro, Suzana Maria Gico Lima (Orientadora). II. Ribeiro Neto, Alfredo (Coorientador). III. Título. UFPE 624 CDD (22. ed.) BCTG/2024-81
-------	---

JOÃO MARIA DE ANDRADE

**ESTUDOS HIDROLÓGICOS COM BASE EM GRANDES AMOSTRAS E
DEEP LEARNING: contribuições para aplicações em bacias hidrográficas no Brasil**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para a obtenção do título de Doutor em Engenharia Civil. Área de concentração: Tecnologia Ambiental e Recursos Hídricos.

Aprovada em: 26/06/2024

BANCA EXAMINADORA

participação por videoconferência

Prof. Dr. Anderson Luiz Ribeiro de Paiva (Examinador Interno)
Universidade Federal de Pernambuco

participação por videoconferência

Dr. Rômulo Augusto Jucá Oliveira (Examinador Externo)
Hydro Matters/ Laboratoire d'Etudes en Géophysique et Océanographie Spatiales

participação por videoconferência

Prof. Dr. Rodolfo Luiz Bezerra Nóbrega (Examinador Externo)
University of Bristol

participação por videoconferência

Prof. Dr. Dirceu Silveira Reis Júnior (Examinador Externo)
Universidade de Brasília

participação por videoconferência

Prof. Dr. Carlos de Oliveira Galvão (Examinador Externo)
Universidade Federal de Campina Grande

Dedico este trabalho aos meus pais, irmãs e minha noiva por todo suporte e amor. E ao povo do sertão Nordestino.

AGRADECIMENTOS

Primeiramente, agradeço a Deus por me conduzir com saúde, esperança e resiliência ao longo desta jornada. Aos meus pais, Benedita e Manoel, por toda a força e perseverança de criar a mim e minhas irmãs no sertão, e por todo o apoio e carinho. Às minhas irmãs, Polianna e Moanna, pelo cuidado e atenção. À minha amada noiva Carol, pelo companheirismo em todos os momentos e à sua família por todo o acolhimento, amor, incentivo e paciência.

Ao meu orientador, Dr. Alfredo Ribeiro Neto, um exemplo de sabedoria, simplicidade e assertividade, que sou profundamente grato pelos ensinamentos, parceria e apoio ao longo de toda a minha trajetória acadêmica no doutorado. À minha orientadora, Dra. Suzana Montenegro, um ícone da hidrologia no Brasil, agradeço imensamente por sua paciência e apoio incondicional ao longo do meu doutorado.

À Universidade Federal de Pernambuco pelos recursos disponibilizados para o desenvolvimento da minha pesquisa. E aos meus amigos e companheiros do Laboratório de Hidráulica da UFPE, agradeço por todas as conversas e reflexões. E ao INCT Observatório Nacional de Segurança Hídrica e Gestão Adaptativa (CNPq-Proc. 406919/2022-4).

Ao Dr. Rodolfo Nóbrega, minha gratidão por me acolher na *University of Bristol* durante meu programa de doutorado sanduíche e por ser um exemplo de competência, seriedade e ética. Gostaria de estender meus agradecimentos a todos os meus colegas e funcionários do laboratório da Escola de Geografia da *University of Bristol*, pela oportunidade de trabalhar e compartilhar experiências em um dos melhores departamentos de hidrologia do Reino Unido.

Aos amigos Luiz, Kate, Shuoyuan Ling, Caroline Dias, pelos momentos de descontração durante meu intercâmbio acadêmico na Inglaterra. E à Susannah Harlow, minha landlady inglesa, pelos conselhos e excelente acolhida em sua casa durante meu período na cidade de Bristol.

Também sou grato a vários cientistas que contribuíram direta ou indiretamente para o desenvolvimento deste trabalho, uma lembrança especial para Dr. Carlos Galvão, Dr. John Cunha, Dr. Higor Costa, Dr. Michel Velaskes, Dra. Gemma Coxon, Dr. Paul Bates e Dr. Almir Cirilo. E em especial, ao meu amigo Dr. Ulisses Alencar, pelo apoio, companheirismo e troca de conhecimentos desde o mestrado até o doutorado.

A secretaria do PPGEC, pela eficiência e disponibilidade nos momentos de necessidade, em especial à Andrea e Juliana.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

“Da água brotou a vida. Os rios são o sangue que nutre a terra, e são feitas de água as células que nos pensam, as lágrimas que nos choram e a memória que nos recorda” (Galeano, 2012, p.95)

RESUMO

Os produtos de precipitação baseados em satélite e reanálise são amplamente adotados como informações complementares às medições *in situ* para estimar a precipitação e a vazão do rio usando modelagem hidrológica. No entanto, ainda existe uma lacuna na literatura sobre a investigação desses produtos nas bacias hidrográficas tropicais e subtropicais usando modelagem hidrológica em grande amostragem e análise de sensibilidade. Além disso, a regionalização da vazão tem recebido grande atenção da comunidade hidrológica e a utilização de *deep learning* como as redes neurais de *Long Short-Term Memory* (LSTM) é um dos caminhos para o aperfeiçoamento da modelagem hidrológica nessas bacias. Assim, o principal objetivo desta tese é aperfeiçoar a estimativa de precipitação e vazão das bacias brasileiras utilizando dados de sensoriamento remoto e reanálise de precipitação (CHIRPS, ERA5, ERA5-Land, GLDAS, IMERG, MERRA-2, PERSIANN-CDR, TRMM, TerraClimate), modelagem hidrológica (GR4J) e *deep learning*. Os resultados mostraram que os produtos de precipitação tendem a superestimar a precipitação, com exceção do ERA5 e MERRA-2. O CHIRPS é o único produto que produz estimativas imparciais de precipitação para a maioria das bacias hidrográficas. CHIRPS, IMERG e MERRA-2 mostraram boa precisão em termos de estimativa de precipitação e desempenho de simulação hidrológica na fase de calibração. No período de validação, os melhores produtos em termos de KGE foram CHIRPS, IMERG e TRMM (KGE > 0,64). Além disso, os erros nos produtos de precipitação são melhor compensados via modelagem hidrológica em regiões de maior umidade e a sensibilidade dos parâmetros do modelo varia de acordo com a precipitação, o clima e a aridez da bacia. No geral, todos os produtos de precipitação exibiram o seu pior desempenho hidrológico em regiões mais áridas. Outros achados da tese indicam que as redes LSTM têm o potencial de auxiliar a regionalização de vazão utilizando as características das bacias em regiões secas e úmidas. Cerca de 88% e 40% das bacias úmidas e secas, respectivamente, apresentaram valores de KGE > 0.6 no modelo regional de LSTM na fase de teste. De modo geral, essa tese fornece informações relevantes sobre a confiabilidade dos produtos de precipitação por satélite/reanálise e uso de *deep learning* para simulação de vazões, e esses achados podem auxiliar aplicações hidrometeorológicas, estudos de alterações climáticas, gestão de recursos hídricos e desastres, especialmente em regiões com escassez de estações de medição de precipitação e vazão.

Palavras-chave: LSTM; produto de precipitação de satélite; séries hidrológicas; modelagem chuva-vazão.

ABSTRACT

Satellite-based and reanalysis precipitation products are widely adopted as complementary information to in situ measurements to estimate precipitation and streamflow using hydrological modelling. However, there is still a gap in the literature investigating these products in tropical and subtropical catchments using large-sample hydrology and sensitivity analysis. Furthermore, flow regionalisation has received a great deal of attention from the hydrological community, and the use of deep learning, such as Long Short-Term Memory (LSTM) neural networks, is one of the ways to improve hydrological modelling in tropical and subtropical catchments. Thus, the main objective of this thesis is to improve the estimation of precipitation and streamflow in Brazilian catchments using remote sensing data and precipitation reanalysis (CHIRPS, ERA5, ERA5-Land, GLDAS, IMERG, MERRA-2, PERSIANN-CDR, TRMM, TerraClimate), hydrological modelling (GR4J) and deep learning. The results showed that precipitation products, except ERA5 and MERRA-2, tend to overestimate precipitation. CHIRPS is the only product that produces unbiased precipitation estimates for most river basins. CHIRPS, IMERG and MERRA-2 showed good accuracy in terms of precipitation estimation and hydrological simulation performance in the calibration phase. In the validation period, the best products in terms of KGE were CHIRPS, IMERG, and TRMM ($KGE > 0.64$). In addition, the errors in the precipitation products are better compensated for by hydrological modelling in regions of higher humidity, and the sensitivity of the model parameters varies according to the precipitation, climate and aridity of the catchment. Overall, all precipitation products exhibited their worst hydrological performance in more arid regions. In addition, the findings of this study indicate that LSTM networks have the potential to aid flow regionalisation using the characteristics of catchments in dry and wet regions. Around 88% and 40% of the wet and dry catchments, respectively, showed KGE values >0.6 in the regional LSTM model in the test phase. Overall, this thesis provides relevant information on the reliability of satellite precipitation products/analysis and the use of deep learning for streamflow simulation; these findings can help numerous hydrometeorological applications, climate change studies, water resources management and disasters, especially in regions with a relatively sparse density of precipitation and streamflow measurement stations.

Keywords: LSTM; satellite precipitation product; hydrological series; rainfall-runoff modelling.

LISTA DE FIGURAS

Figura 1 – Resumo da organização da tese, a conexão entre os cinco capítulos e o fluxograma específico para cada tópico de pesquisa.....	23
Figura 2 – Localização do NEB. A) Classificação climática de Köppen para o NEB (de acordo com Alvares et al., 2013; A, B e C representam as zonas climáticas Tropical, Semiárida e Subtropical Úmida, respectivamente) e R1, R2 e R3 são sub-regiões definidas pelo período chuvoso (contornos amarelos; adaptado de Lucena et al, 2011; Cunha et al., 2015; Costa et al., 2020), B) localização dos biomas presentes no NEB e distribuições espaciais da precipitação média anual (mm) entre 2001-2019 (Xavier et al., 2022).....	30
Figura 3 – Distribuições espaciais de A)PBIAS, B) r, C)RMSE e D)RRMSE da precipitação mensal do CHIRPS, ERA5-Land, IMERG, TerraClimate e TRMM em comparação com a precipitação observada para o período 2001-2019 no NEB. Os valores médios de PBIAS, r, RMSE e RRMSE também são fornecidos para cada produto de precipitação	36
Figura 4 – Boxplots das métricas de desempenho A) PBIAS,B) r, C) RMSE e D) RRMSE para cada mês de 2001 a 2019 para os produtos de precipitação (CHIRPS, ERA5-Land, IMERG, TerraClimate e TRMM) no NEB	38
Figura 5 – Valores medianos das métricas de desempenho (PBIAS, r, RMSE e RRMSE) por mês do ano de 2001 a 2019 para os produtos de precipitação (CHIRPS, TRMM, IMERG, ERA5-Land e TerraClimate) para três sub-regiões definidas pelo período chuvoso: (R1) janeiro a junho; (R2) março a agosto; e (R3) novembro a abril (adaptado de Lucena et al., 2011; Cunha et al., 2015; Costa et al., 2020). TERRAC: TerraClimate, ERA5L: ERA5-Land.....	39
Figura 6 – Boxplot das métricas A) PBIAS, B) r, C) RMSE e D) RRMSE dos produtos CHIRPS, TRMM, IMERG, ERA5-Land e TerraClimate para cada bioma do NEB (Amazônia, Caatinga, Cerrado e Mata Atlântica) para precipitação mensal	41
Figura 7 – Precipitação média mensal derivada da precipitação observada e dos produtos CHIRPS, TRMM, IMERG, ERA5-Land e TerraClimate em cada bioma do NEB: A) Amazônia, B) Mata Atlântica, C) Caatinga e D) Cerrado para o período de 2001-2019.....	42

Figura 8 – Distribuições espaciais de A)PBIAS, B) r, C)RMSE e D)RRMSE da precipitação anual do CHIRPS, ERA5-Land, IMERG, TerraClimate e TRMM em comparação com a precipitação observada para o período de 2001 a 2019 no NEB	43
Figura 9 – Boxplot das métricas A) PBIAS, B) r, C) RMSE e D)RRMSE dos produtos CHIRPS, ERA5-Land, IMERG, TerraClimate e TRMM para cada bioma do NEB (Amazônia, Caatinga, Cerrado e Mata Atlântica) para precipitação anual	44
Figura 10 – Distribuição espacial da precipitação média anual para o período 2001-2019 a partir da precipitação observada e dos produtos de precipitação (CHIRPS, ERA5-Land, IMERG, TerraClimate e TRMM)	45
Figura 11 – Localização e características da região de estudo: a) Classificação climática de Köppen para o Brasil (de acordo com Alvares et al, 2013). b) Mapa de localização contendo as 714 bacias hidrográficas (saídas mostradas por pontos vermelhos) nas quais os produtos de precipitação foram avaliados. Para cada região hidrográfica, a precipitação média de longo prazo da área e o fluxo médio de todas as bacias hidrográficas dentro dela são representados nos subquadros. As áreas sombreadas (cinza) representam a faixa de fluxo diário para as regiões hidrográficas	53
Figura 12 – Diagrama esquemático do modelo chuva-escoamento GR4J	58
Figura 13 – Distribuição espacial das pontuações de desempenho para os sete diferentes produtos de precipitação (CHIRPS, ERA5, GLDAS, IMERG, MERRA-2, PERSIANN-CDR e TRMM) quando comparados com medições de precipitação médias baseadas na bacia hidrográfica	62
Figura 14 – Boxplots de métricas de desempenho (r, pbias, RMSE) para os produtos de precipitação (CHIRPS, ERA5, GLDAS, IMERG, MERRA-2, PERSIANN-CDR e TRMM) para todas as bacias hidrográficas	62
Figura 15 – Valores medianos das métricas de desempenho (r, pbias, RMSE) para os produtos de precipitação por região hidrográfica, classificados do mais chuvoso (superior) ao mais seco (inferior) de acordo com o índice de aridez	63
Figura 16 – Funções de distribuição cumulativa (CDF) do KGE para a precipitação com base em pluviômetros e os sete produtos de precipitação diferentes na simulação da vazão diária dos rios nas bacias brasileiras nas fases de calibração e validação.....	64

Figura 17 – Métricas de desempenho r , p bias e KGE para os sete diferentes produtos de precipitação na simulação da vazão diária dos rios das bacias brasileiras	68
Figura 18 – Diagrama das doze regiões hidrográficas em ordem decrescente por índice de aridez do Brasil para a precipitação de referência (GB) e os sete produtos para a fase de calibração. O tamanho de cada círculo indica o valor KGE mediano das bacias hidrográficas localizadas em uma dada região hidrográfica e um dado produto de precipitação. A cor de cada círculo indica o valor p bias mediano	69
Figura 19 – A diferença relativa entre os resultados r das avaliações diárias da vazão do rio e da precipitação para produtos de precipitação (CHIRPS, ERA5, GLDAS, IMERG, PERSIANN-CDR, MERRA-2 e TRMM) na calibração e validação para abordagem II.	70
Figura 20 – Melhores valores de KGE para o período de calibração. A) Todos os produtos de precipitação, incluindo chuvas terrestres. B) Todos os produtos de precipitação, excluindo a precipitação baseada em medições terrestre	70
Figura 21 – Boxplot do <i>Total Sensitivity Indices</i> (TSI) do Sobol para os parâmetros GR4J para as 714 bacias analisadas	71
Figura 22 – Sensibilidade dos parâmetros do modelo hidrológico para cada conjunto de dados de entrada de precipitação. As bacias hidrográficas são classificadas por região hidrográfica de acordo com o índice de aridez (bacias mais secas à esquerda, bacias mais úmidas à direita)	72
Figura 23 – Área de estudo e localização das bacias hidrográficas. A) Mapa de localização contendo as saídas das 54 bacias hidrográficas secas (Dry) e 122 bacias úmidas (Wet). Para cada região, a precipitação média de longo prazo da área (azul) e o fluxo médio de todas as bacias hidrográficas dentro dela são representados: B) bacias secas (Dry) e C) bacias úmidas (Wet). As áreas sombreadas (cinza) representam a faixa de vazão diária para as regiões hidrográficas	82
Figura 24 – Características de cada bacia hidrográfica: a) precipitação (mm/ano), b) PET (mm/ano), c) Vazão em mm/ano e d) média da elevação (m)	83
Figura 25 – Estrutura da célula de memória LSTM: processamento de dados da última	85
Figura 26 – Variações de desempenho do LSTM em relação ao comprimento das sequências de entrada (<i>lookback</i>) dentro de diferentes regimes para o modelo regional de LSTM: a) regime seco (<i>Dry</i>) e b) regime úmido (<i>Wet</i>). Em cada painel, as linhas	

correspondem às pontuações medianas do KGE da fase de treino, validação e teste respectivamente	88
Figura 27 – Funções de distribuição acumulada (CDF) do KGE do modelo regional de LSTM para as bacias da região seca (<i>Dry</i>) e úmida (<i>Wet</i>) na fase de teste	89
Figura 28 – Distribuição espacial das pontuações de desempenho de KGE para o modelo regional de LSTM para as fases de treino, validação e teste	90
Figura 29 – Dispersão entre KGE do modelo regional de LSTM da fase de teste e os vários descritores de bacia hidrográfica utilizados neste estudo (Tabela 9) para cada uma das 176 bacias estudadas: A) 54 bacias secas e B) 122 bacias úmidas. Os coeficientes de correlação r são exibidos em cada gráfico	91
Figura 30 – <i>Boxplots</i> das pontuações de desempenho de KGE obtidas para 174 bacias hidrográficas distribuídas na região seca e úmida: a) Modelo de LSTM regional, b) Modelo de LSTM composto e c) Modelo GR4J	92
Figura 31 – Distribuição espacial da diferença entre a fase de teste do modelo de LSTM regional e GR4J	92

LISTA DE TABELAS

Tabela 1 – Resumo dos estudos relevantes que avaliam diferentes produtos de precipitação em escalas continental e regional	28
Tabela 2 – Resumo dos produtos baseados em satélite que fornecem dados diários e mensais em escala global sobre o GEE	32
Tabela 3 – Lista de métricas estatísticas para avaliação dos produtos de precipitação	35
Tabela 4 – Resumo da média e do desvio padrão (sd) das estatísticas descritivas da precipitação mensal no NEB. Os melhores valores são mostrados em negrito.....	37
Tabela 5 – Valores médios diários de variáveis climáticas e hidrológicas para as regiões hidrográficas do Brasil.....	54
Tabela 6 – Cobertura espacial e temporal e resolução dos produtos de precipitação	55
Tabela 7 – Mediana e desvio padrão (valor mostrado entre parênteses) das métricas estatísticas para simulação de descarga para todas as 714 bacias hidrográficas selecionadas usando a abordagem de calibração I.....	65
Tabela 8 – Mediana e desvio padrão (valores mostrados entre parênteses) de métricas estatísticas para simulação de descarga para todas as 714 bacias hidrográficas selecionadas usando a abordagem de calibração II	66
Tabela 9 – Lista dos recursos dinâmicos e estáticos usados em diferentes modelos LSTM....	84

LISTA DE ABREVIATURAS E SIGLAS

ANA	Agência Nacional de Águas e Saneamento Básico
CABra	Catchment Attributes for Brazil
CHG	Climate Hazards Group
CHIRPS	Climate Hazards Group InfraRed Precipitation with Station data
ERA5	European Centre for Medium-Range Weather Forecasts ReAnalysis 5
ERA5-Land	European Centre for Medium-Range Weather Forecasts ReAnalysis 5 – Land
GEE	Google Earth Engine
GLDAS	Global Land Data Assimilation System
GPM	Global Precipitation Measurement
GR4J	Génie Rural Journalier 4
HGA	Hidrologia de grandes amostras
IMERG	Integrated Multi-satellite Retrievals for GPM
INMET	Instituto Nacional de Meteorologia
JRA55	Reanálise Japonesa de 55 anos
KGE	Kling-Gupta efficiency
LSTM	Long Short-Term Memory
MERRA	Modern-Era Retrospective analysis for Research and Applications
ML	Machine Learning
NCDC	NOAA National Climate Data Center
NEB	Nordeste do Brasil
NE	Nordeste
NSE	Nash-Sutcliffe efficiency
Pbias	Percent bias
PET	Potential evapotranspiration
PERSIANN-CDR	Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks - Climate Data Record
RMSE	Root mean square error
RRMSE	Relative root mean square error
TRMM	Tropical Rainfall Measuring Mission
USGS	United States Geological Survey
WMO	World Meteorological Organization

SUMÁRIO

1	INTRODUÇÃO	18
1.1	HIPÓTESE E QUESTÕES DE PESQUISA	21
1.2	OBJETIVOS	22
1.2.1	Objetivo geral	22
1.2.2	Objetivos específicos	22
1.3	ORGANIZAÇÃO DA TESE	22
2	AVALIAÇÃO DOS PRODUTOS DE PRECIPITAÇÃO: ANÁLISES TEMPORAIS E ESPACIAIS SOBRE BIOMAS TERRESTRES NO NORDESTE DO BRASIL.....	25
2.1	INTRODUÇÃO	25
2.2	MÉTODOS E DADOS	30
2.2.1	Área de estudo	30
2.2.2	Conjuntos de dados de precipitação.....	31
2.2.2.1	Precipitação observada.....	31
2.2.2.2	Produtos de precipitação	32
2.2.3	Estatísticas de validação	34
2.2.4	Análise espacial e sazonal.....	35
2.3	RESULTADOS.....	36
2.3.1	Análise espacial em escala mensal.....	36
2.3.2	Análise sazonal	37
2.3.3	Desempenho por bioma em escala mensal.....	40
2.3.4	Avaliação à escala anual.....	42
2.4	DISCUSSÃO	45
2.5	CONCLUSÃO	47
3	EFICIÊNCIA DOS PRODUTOS DE PRECIPITAÇÃO PARA MODELAGEM HIDROLÓGICA UTILIZANDO GRANDE AMOSTRAGEM DE BACIAS HIDROGRÁFICAS TROPICAIS E SUBTROPICAIS.....	49
3.1	INTRODUÇÃO	50
3.2	ÁREA DE ESTUDO E CONJUNTOS DE DADOS.....	52
3.2.1	Área de estudo	52
3.2.2	Conjunto de dados	54
3.2.2.1	Precipitação baseada em satélite e reanálise	54

3.2.2.2	Vazão, precipitação e evapotranspiração observadas	56
3.3	METODOLOGIA	57
3.3.1	Calibração e validação do modelo hidrológico.....	58
3.3.2	Métricas estatísticas para avaliar estimativas de precipitação e vazão	60
3.3.3	Análise de sensibilidade.....	61
3.4	RESULTADOS.....	61
3.4.1	Precisão dos produtos de precipitação em relação à precipitação de referência	61
3.4.2	Avaliação hidrológica nas bacias brasileiras	64
3.4.2.1	Análise da simulação hidrológica baseada na calibração da Abordagem I	64
3.4.2.2	Análise da simulação hidrológica baseada na calibração da Abordagem II	66
3.4.3	Sensibilidade dos parâmetros do modelo GR4J.....	71
3.5	DISCUSSÃO	72
3.5.1	Desempenho da estimativa de precipitação média na escada de bacia hidrográfica	72
3.5.2	Desempenho da modelagem hidrológica.....	73
3.5.3	Análise de sensibilidade.....	75
3.6	CONCLUSÃO	76
4	SIMULAÇÕES DE VAZÃO NAS BACIAS TROPICAIS E SUBTROPICAIS COM MODELOS REGIONALIZADOS DE REDES NEURAIS DE LONG SHORT-TERM MEMORY (LSTM) EM REGIMES HIDROGRÁFICOS CONTRASTANTES	78
4.1	INTRODUÇÃO	79
4.2	DADOS	81
4.2.1	Dados hidrometeorológicos	81
4.2.2	Classificação da bacia hidrográfica.....	81
4.2.3	Atributos físicos e climáticos da bacia hidrográfica	83
4.3	METODOLOGIA	84
4.3.1	Long short-term memory (LSTM).....	84
4.3.2	Configurações dos inputs e abordagens para modelagem da LSTM.....	86
4.3.3	Ajuste de hiperparâmetros e taxa de aprendizagem	86
4.3.4	Modelo de referência conceitual: GR4J.....	87
4.3.5	CrITÉrios para avaliação de desempenho	88

4.4	RESULTADOS.....	88
4.4.1	Variação do desempenho do LSTM por região climática	88
4.4.2	Comparação de desempenho entre diferentes abordagens de treinamento da LSTM e o modelo GR4J	91
4.5	DISCUSSÃO	93
4.5.1	O padrão retrospectivo (<i>lookback</i>) e a variabilidade espacial do desempenho das LSTMs	93
4.5.2	Comparação entre as diferentes abordagens de regionalização da LSTM com um modelo hidrológico conceitual	94
4.6	CONCLUSÃO	95
5	CONCLUSÕES GERAIS.....	97
	REFERÊNCIAS	99
	APÊNDICE A – A COMPREHENSIVE ASSESSMENT OF PRECIPITATION PRODUCTS: TEMPORAL AND SPATIAL ANALYSES OVER TERRESTRIAL BIOMES IN NORTHEASTERN BRAZIL	118
	APÊNDICE B – EFFICIENCY OF GLOBAL PRECIPITATION DATASETS IN TROPICAL AND SUBTROPICAL CATCHMENTS REVEALED BY LARGE SAMPLING HYDROLOGICAL MODELLING	134
	APÊNDICE C – MATERIAL SUPLEMENTAR: CAPÍTULO 2.....	149
	APÊNDICE D – MATERIAL SUPLEMENTAR: CAPÍTULO 3.....	155

1 INTRODUÇÃO

A distorção do ciclo da água, particularmente de seus extremos (cheias e secas), estará entre as consequências mais visíveis das mudanças climáticas (Rodell; Li, 2023). A segurança hídrica está em risco para bilhões de pessoas em todo o mundo e a situação tende a se agravar nas próximas décadas (Oki; Kanae, 2006; UN-Water, 2013). A escassez de água é um grande problema no mundo atual de 8 bilhões de pessoas, além disso, a pressão sobre o sistema de água aumentará até 2050, quando a população mundial deverá atingir entre 9,4 e 10,2 bilhões (Boretti; Rosa, 2019). Por outro lado, eventos de cheias que causaram inundações afetaram mais de 2 bilhões de pessoas entre 1998 e 2017 (Eckstein et al., 2018). Diante disso, o desenvolvimento de sistemas globais de monitoramento de precipitação e de modelagem hidrológica que possam dar suporte a estudos de alerta de seca e inundação tem sido um objetivo dos esforços de pesquisa em hidrologia (Bastiaanssen et al., 2015; Seyyedi et al., 2015; Almagro et al., 2021a; Delaney et al., 2020; Bevacqua et al., 2021; Getirana et al., 2021; Hapuarachchi et al., 2022; AghaKouchak et al., 2023).

O Brasil apresenta vulnerabilidade aos eventos de secas e cheias (Marengo et al., 2017; Cunha et al., 2019). Por exemplo, entre os anos de 2011 a 2019, quase todo o seu território foi exposto à seca mais severa e intensa dos últimos 60 anos; e mais de 75% da área do nordeste brasileiro (NEB) sofreu eventos excepcionais de seca (Souza Santos et al., 2024). Por outro lado, eventos de chuvas e cheias extremas também estão ocorrendo com maior frequência, chuvas intensas no leste do NEB em Maio de 2022 provocaram inundações generalizadas e deslizamentos de terra, resultando em 133 mortes e mais de 25 mil pessoas deslocadas, atingindo com maior intensidade a região metropolitana do Recife-PE (Chagas Junior et al., 2024); e entre os meses de Abril e Maio de 2024, chuvas e cheias extremas atingiram aproximadamente 80% do estado do Rio Grande do Sul, afetando mais 2,1 milhões de pessoas (SECOM RS, 2024). As informações hidrometeorológicas, como dados de precipitação e vazão, são de extrema importância, especialmente em cenários de eventos extremos, para auxiliar a gestão e gerenciamento da água para abastecimento humano, produção de alimentos e operação de hidrelétricas e mitigações dos impactos das secas e cheias (Marengo et al., 2017; Almagro et al., 2021a; Bevacqua et al., 2021; Getirana et al., 2021).

No entanto, a falta de dados hidrometeorológicos como por exemplo a escassez de registros de fluxo de água é um problema universal na hidrologia, mas evidente especialmente nos países em desenvolvimento onde existem recursos limitados para a coleta e gestão de dados

(Serrat-Capdevila et al., 2016). As medições *in situ* de precipitação e vazão estão sujeitas a limitações, incluindo cobertura espacial esparsa, lacunas temporais e inconsistências nas medições (Chen et al., 2018). A baixa densidade de pluviômetros e alta proporção de dados faltantes e registros de curta duração inviabilizam a análise confiável da chuva em algumas partes do mundo, como por exemplo, em muitas regiões da África e América do Sul em que a densidade de postos pluviométricos é de aproximadamente uma estação a cada 100.000 km² (Brocca et al., 2020). O Brasil apresenta uma distribuição espacial e temporal heterogênea de estações de medição de vazão e precipitação (Gadelha et al., 2019; Chagas et al., 2020; Xavier et al., 2022), apesar de ser o quinto maior país e está frequentemente entre as 10 maiores economias do mundo. A escassa alocação de recursos para o monitoramento hidrometeorológico no país, incluindo precipitação e vazão, cria dificuldades, sendo um grande desafio para gestão e gerenciamento dos recursos hídricos (Chagas et al., 2020; Almagro et al., 2021b). No país, a densidade de medidores de vazão fica abaixo dos padrões recomendados pela *World Meteorological Organization* (WMO) de 1 estação para cada 1.000 km², além das observações estarem frequentemente interrompidas (WMO, 2010; Chagas et al., 2020; Almagro et al., 2021a).

Diante deste cenário, o sensoriamento remoto oferece uma boa oportunidade para medição de variáveis ciclo hidrológico, como precipitação, umidade do solo e armazenamento de água por exemplo (Chen et al., 2018). Esses conjuntos de dados globais e independentes para os diferentes componentes dos ciclos de água e energia auxiliam o monitoramento e beneficiam as ciências hidrológicas (Alfieri et al., 2018; Alfieri et al., 2022; Chen et al., 2018), uma vez que a hidrologia e os processos hidrológicos são caracterizados por alta variabilidade espaço-temporal (Klingler et al., 2021). Os produtos de precipitação globais e continentais baseados em satélites e reanálise permitem estudar a alta variabilidade espaço-temporal da precipitação em escala mundial para aplicação em estudos de modelagem hidrológica (Camici et al., 2018; Almagro et al., 2021b), monitoramentos hidrológicos e climáticos (Dembélé; Zwart, 2016), identificação de secas meteorológicas (Santos et al., 2017; Brito et al., 2021) e eventos de inundação (Toté et al., 2015). Nas últimas décadas, esforços têm sido feitos por várias instituições e organizações globais para liberar dados de precipitação baseados em satélite com diferentes resoluções e coberturas espaço-temporais (Xu et al., 2022).

Os produtos de precipitação de satélite medem a precipitação usando vários algoritmos de recuperação baseados em estatística e/ou física com as informações de radiância dos sensores transportados por satélite, incluindo sensores do visível e infravermelho, sensores de

microondas passivos e sensores de microondas ativos (Kidd; Huffman, 2011; Sun et al., 2020). No entanto, as estimativas de precipitação por satélite estão sujeitas a várias fontes de erro, como limitações do sensor, medição e sinais de sensoriamento remoto (Huffman et al., 2007; Kidd; Huffman, 2011). Já os produtos de precipitação baseados em reanálise utilizam um processo de assimilação de várias fontes de dados (estações terrestres, navios, aviões e satélites) e modelos de previsão meteorológicos, com o objetivo de fornecer dados de precipitação de longo prazo que podem dar suporte a análises de frequência global de extremos hidrológicos (Seyyedi et al., 2015; Parker, 2016). Porém, esses produtos também estão sujeitos a erros e incertezas inerentes às observações, dados forçantes, tecnologias de assimilação de dados e parametrizações de modelos de previsão (Hoffman et al., 2017).

Um registro temporal longo e confiável de precipitação permite auxiliar a modelagem hidrológica para simulação das vazões (Baethgen; Goddard, 2013; Toté et al., 2015). Existe uma ampla gama de técnicas de modelagem hidrológica para simulação de vazão, como os modelos conceituais, os modelos de base física e modelos baseados em dados (Horton et al., 2022; Hapuarachchi et al., 2022). Na modelagem hidrológica conceitual é feita uma abstração sobre os vários processos hidrológicos subjacentes à observação, e toda a bacia costuma ser considerada homogênea (Horton et al., 2022). Os modelos de base física utilizam informações espacialmente distribuídas e são mais complexos, exigindo um esforço computacional significativo para parametrização (Jajarmizadeh et al., 2012; Noori; Kalin, 2016). Contudo, a parametrização de um modelo hidrológico de base física ou conceitual para qualquer bacia hidrográfica pode ser complexa, o que torna difícil a parametrização do modelo quando os dados hidrológicos não estão disponíveis em uma determinada bacia hidrográfica (Li et al., 2022). Nesse contexto, a regionalização, definida como "a extrapolação de informações hidrológicas de uma área para outra" (Blöschl; Sivapalan, 1995), surge como um tópico importante na hidrologia e uma alternativa para bacias sem mediação de vazão. Além disso, um problema recorrente na hidrologia seria como usar um modelo, ou um conjunto de modelos, para fornecer simulações hidrológicas espacialmente contínuas em grandes áreas em escala regional, continental ou global (Kratzert et al., 2019).

Nesse cenário, a abordagem de modelagem baseada em dados pode fornecer um modelo hidrológico regionalizado de chuva-vazão que simplifica a representação dos processos hidrológicos e que pode se assemelhar a performance de um modelo de base física (Nogueira Filho et al., 2022). Os modelos baseados em dados e abordagens de aprendizado profundo (*deep learning*) ganharam recentemente atenção significativa na hidrologia (Sit et al., 2020), devido

ao excelente desempenho na previsão de séries temporais e sua capacidade de identificar padrões nos dados (Kratzert et al., 2018; Kratzert et al., 2019), e sua capacidade de produzir um modelo em escala regional ou nacional para bacias medidas e não medidas (Beven, 2020; Hashemi et al., 2022; Arsenault et al., 2023). No entanto, essas abordagens dependem fortemente da disponibilidade dos conjuntos de dados de grandes amostras (Gupta et al., 2014; Kratzert et al., 2019; Addor et al., 2020).

A hidrologia de grandes amostras (HGA) que faz uso de vastos conjuntos de bacias hidrográficas permite obter conclusões robustas sobre processos e modelos hidrológicos e verificar a similaridade entre as bacias (Addor et al., 2020). Gupta et al. (2014) indicam que os princípios hidrológicos gerais devem ser derivados de relações estatisticamente significativas, que podem ser obtidos a partir de grandes amostras de dados. Entretanto, no Brasil e outros países situados nos trópicos, ainda existem lacunas de estudos hidrológicos com grandes amostras que procurem aperfeiçoar a modelagem hidrológica a partir de novos dados de sensoriamento remoto e reanálise que permita um monitoramento contínuo dos recursos hídricos.

1.1 HIPÓTESE E QUESTÕES DE PESQUISA

A hipótese central desta tese é que os produtos de precipitação de satélite ou reanálise e modelos hidrológicos baseados em dados (*deep learning*) podem ser uma alternativa eficaz para auxiliar a estimativa da precipitação e vazão nas bacias hidrográficas brasileiras.

As principais questões de pesquisa são:

- a) Quão adequados são os produtos de precipitação e reanálise na estimativa de precipitação?
- b) Qual o impacto da utilização dos produtos de precipitação e reanálise para simulação da vazão nas bacias hidrográficas brasileiras?
- c) A regionalização da vazão a partir de um modelo de *deep learning* pode melhorar a simulação da vazão?

Para responder essas questões, foi necessário utilizar um abrangente conjunto de dados derivados de observações *in situ*, dados de sensoriamento remoto e reanálise em diversas

escalas espaciais e temporais, técnicas de sensoriamento remoto, *deep learning* e processamento de dados.

1.2 OBJETIVOS

1.2.1 Objetivo geral

O principal objetivo desta tese é aperfeiçoar a estimativa da precipitação e vazão das bacias brasileiras utilizando dados de sensoriamento remoto e reanálise de precipitação, modelagem hidrológica e *deep learning*.


1.2.2 Objetivos específicos

- a) Avaliar diferentes produtos de precipitação baseados em satélite e reanálise em regiões tropicais.
- b) Compreender a utilidade hidrológica dos produtos de precipitação para simulação da vazão nas bacias hidrográficas em uma estrutura de modelagem hidrológica.
- c) Analisar a utilização de técnica de *deep learning* para a simulação do escoamento em bacias tropicais e subtropicais.

1.3 ORGANIZAÇÃO DA TESE

A tese está organizada em cinco capítulos, um capítulo de introdução, três capítulos de pesquisa, um capítulo de conclusão e apêndices. Cada capítulo de pesquisa aborda uma questão de pesquisa especificada no item 1.1. A Figura 1 apresenta uma visão geral de como os diferentes capítulos se relacionam entre si e o fluxograma específico de cada capítulo de pesquisa.

Figura 1 – Resumo da organização da tese, a conexão entre os cinco capítulos e o fluxograma específico para cada tópico de pesquisa



Cap: Capítulo, NEB: Nordeste do Brasil, Prec: precipitação, Sens: sensibilidade, LSTM: *Long short-term memory*

Fonte: O Autor (2024).

O **Capítulo 1** apresenta a visão geral da pesquisa, motivação, os objetivos da pesquisa e as questões fundamentais abordadas e esboço da tese. **Capítulo 2** fornece uma visão geral da utilidade de três produtos de precipitação baseados em satélite (CHIRPS, IMERG e TRMM) e dois produtos baseados em modelos (ERA5-Land e TerraClimate) em diferentes biomas tropicais localizados no Nordeste do Brasil. É avaliada a qualidade desses produtos durante o período de 2001-2019, comparando com os dados observados de precipitação nas escalas

mensal, sazonal e anual. Além disso, indicamos os principais erros sistemáticos dos produtos e suas principais causas para cada bioma do Nordeste brasileiro. Os resultados obtidos informam os usuários sobre os pontos fortes e fracos desses produtos e ajudarão a selecionar o conjunto de dados apropriados com base em suas respectivas aplicações.

Capítulo 3 trata-se de uma avaliação sobre a capacidade de quatro produtos de precipitação baseados em satélite (CHIRPS, IMERG, TRMM, PERSIANN-CDR), e três de reanálise (ERA5, MERRA-2, GLDAS) para estimar a precipitação sobre o Brasil na escala de bacia hidrográfica. Além disso, é investigada de forma abrangente a utilidade hidrológica desses produtos de precipitação através de uma estrutura de avaliação hidrológica, empregando o modelo hidrológico de chuva-vazão GR4J em 714 bacias hidrográficas brasileiras. As descobertas deste estudo fornecem uma orientação oportuna e útil sobre a utilização desses produtos de precipitação na modelagem hidrológica para os potenciais usuários finais em diferentes regiões hidroclimáticas.

Capítulo 4 investiga os benefícios da utilização de métodos de estimativa de vazão utilizando algoritmos de *deep learning* em uma estrutura de modelagem hidrológica regionalizada. O objetivo dessa aplicação é desenvolver modelos mais precisos e confiáveis para estimar a vazão nas bacias hidrográficas brasileiras. Para isso, foi utilizado um vasto conjunto de dados de bacias hidrográficas. As estimativas de vazão são necessárias em locais de difícil acesso e com escassez de dados, e são ferramentas valiosas de apoio à gestão dos recursos hídricos. As descobertas desse estudo destacam os pontos fortes e as limitações dos modelos de *deep learning* em regiões hidroclimáticas contrastantes em bacias tropicais e subtropicais. No **Capítulo 5** são apresentadas as principais conclusões encontradas na tese, evidenciando a sua relevância e sugerindo recomendações para trabalhos futuros.

Nos **Apêndices** encontram-se as publicações resultantes dos Capítulos 2 e 3 e algumas análises complementares. O trabalho derivado do Capítulo 2 (Apêndice A), apresenta o seguinte título “*A comprehensive assessment of precipitation products: Temporal and spatial analyses over terrestrial biomes in Northeastern Brazil*” e foi publicado na “*Remote Sensing Applications: Society and Environment*”. O trabalho resultante do Capítulo 3 (Apêndice B), com título “*Efficiency of global precipitation datasets in tropical and subtropical catchments revealed by large sampling hydrological modelling*”, foi publicado na “*Journal of Hydrology*”. E o trabalho resultante do Capítulo 4 está em preparação para submissão.

2 AVALIAÇÃO DOS PRODUTOS DE PRECIPITAÇÃO: ANÁLISES TEMPORAIS E ESPACIAIS SOBRE BIOMAS TERRESTRES NO NORDESTE DO BRASIL

A publicação resultante desse capítulo (Apêndice A) é:

João M. de Andrade, Alfredo R. Neto, Ulisses A. Bezerra, Ana C.C. Moraes, Suzana M. G. L. Montenegro: A comprehensive assessment of precipitation products: Temporal and spatial analyses over terrestrial biomes in Northeastern Brazil. **Remote Sensing Applications: Society and Environment**, 100842. <https://doi.org/10.1016/j.rsase.2022.100842>.

Resumo

Estimativas precisas de precipitação com resolução espaço-temporal são vitais para inúmeras aplicações, incluindo monitoramento agrícola, hidrometeorologia e gestão de recursos hídricos. O Nordeste do Brasil (NEB) é vulnerável à extrema variabilidade climática interanual e a precipitação está intimamente ligada aos meios de subsistência dos seus cidadãos e à saúde regional da economia. Os dados de chuva por satélite são uma fonte alternativa de informação para regiões como o NEB. Assim, este estudo teve como objetivo avaliar o desempenho das estimativas mensais de precipitação derivadas de versões mais recentes de cinco produtos de precipitação: (i) CHIRPS, (ii) ERA5-Land, (iii) TerraClimate, (iv) TRMM e (v) IMERG em o NEB e comparando-os com a precipitação observada para o período 2001–2019. Os resultados mostraram que os produtos baseados em satélite estavam mais regularmente correlacionados com a precipitação observada do que os produtos baseados em modelos. CHIRPS, IMERG e TRMM apresentaram valor médio do coeficiente de correlação de Pearson (r) acima de 0,93. Todos os produtos tenderam a apresentar menor erro relativo nos meses chuvosos; TerraClimate deu o maior valor médio de erro quadrático médio (RMSE) para NEB (41,61 mm/mês). O melhor desempenho global foi observado no bioma Amazônia ($r \sim 0,90$), e o pior no bioma Mata Atlântica, que tendeu a subestimar a precipitação. Apesar dos resultados na Mata Atlântica, este estudo demonstrou que os produtos da precipitação podem ser um complemento útil aos dados de precipitação para o NEB. A avaliação abrangente dos produtos de precipitação aqui relatada servirá como referência para gestores e pesquisadores selecionarem o produto ideal para a aplicação pretendida e as incertezas associadas.

2.1 INTRODUÇÃO

A região Nordeste do Brasil (NEB) abrange uma área de aproximadamente 1,5 milhão de km², correspondendo a 20% do território brasileiro (Martins et al., 2019). A região é

vulnerável a extremos climáticos e será afetada por déficits pluviométricos e aumentos de aridez ao longo deste século (Vieira et al., 2015). A variabilidade das chuvas, a degradação do solo e a desertificação são alguns dos fatores que podem tornar esta região uma das mais vulneráveis às alterações climáticas a nível mundial (Marengo et al., 2017). Os solos no NEB são tipicamente rasos, sobre rochas cristalinas (Silva et al., 2022), retendo água apenas por um curto período após o período chuvoso. A precipitação no NEB está intimamente ligada aos meios de subsistência dos seus cidadãos e à saúde da economia da região, uma vez que a produção agrícola está exposta a uma elevada variabilidade das chuvas, o que afeta a maioria dos agricultores (Nelson; Finan, 2009). Cerca de 80% dos alimentos consumidos na região são fornecidos por pequenos agricultores que utilizam a agricultura de sequeiro, que depende das chuvas e da água armazenada no solo (IBGE, 2019; ANA – Agência Nacional de Águas e Saneamento Básico, 2020). A precipitação é uma das variáveis atmosféricas mais importantes nos ciclos globais de água e energia. Um registo temporal longo e fiável da precipitação é crucial para diferentes aplicações, incluindo modelação hidrológica, monitorização agrícola, hidrometeorologia, gestão de recursos hídricos, monitorização de cheias e secas e aplicações climatológicas (Baethgen; Goddard, 2013; Toté et al., 2015). As observações dos pluviômetros terrestres fornecem medições precisas da precipitação local. No entanto, a baixa densidade do pluviômetro, a alta proporção de dados faltantes e os registos curtos inviabilizam análises confiáveis de precipitação, o que é mais evidente em algumas áreas do NEB (Rodrigues et al., 2020). Além disso, a limitada representatividade espacial e a distribuição não homogênea das estações pluviométricas restringem sua aplicabilidade em escala global (Kidd et al., 2017).

Produtos de precipitação globais e continentais baseados em satélites e modelos oferecem uma oportunidade única para estudar a alta variabilidade espaço-temporal da precipitação em escala mundial para aplicação em estudos e monitoramento hidrológico e climático (Dembélé; Zwart, 2016), identificação de secas meteorológicas (Santos et al., 2017; Brito et al., 2021) e eventos de inundação (Toté et al., 2015). No entanto, essas estimativas têm várias limitações porque nenhum dos sensores de satélite detecta diretamente a chuva; eles sofrem com erros e incertezas originados de várias fontes, incluindo calibração de sensores, aproximações algorítmicas e amostragem (Ramarohetra et al., 2013). Nas últimas décadas, esforços foram feitos por várias instituições e organizações globais para liberar dados de precipitação baseados em satélite com várias resoluções e coberturas espaço-temporais (Xu et al., 2022). O *Tropical Rainfall Measuring Mission* (TRMM), lançada em 1997, tem sido considerada preeminente em medições de precipitação com dados de alta qualidade para

aplicações por quase 20 anos (Huffman et al., 2007; Kidd; Huffman, 2011). Como sucessora da TRMM, a *Global Precipitation Measurement* (GPM) foi lançada em 2014, e o *Integrated Multi-satellite Retrievals for GPM* (IMERG) é um algoritmo unificado que fornece estimativas de precipitação combinando dados de todos os instrumentos passivos de micro-ondas na constelação GPM, fornecendo estimativas aprimoradas de precipitação leve e congelada e resoluções espaço-temporais mais precisas (Kirschbaum et al., 2017; Huffman et al., 2019). No entanto, os produtos de precipitação multi-satélite baseados em TRMM são limitados em uso em aplicações climatológicas, com dados disponíveis apenas de 1998 em diante. Portanto, para preencher a lacuna na disponibilidade de produtos de precipitação multi-satélite de alta resolução antes de 1998, um novo banco de dados climáticos de precipitação terrestre, o *Climate Hazards Group InfraRed Precipitation with Station data* (CHIRPS), foi desenvolvido (Funk et al., 2015). O CHIRPS abrange três tipos diferentes de informações: climatológicas globais, estimativas de satélite e observações in situ; pertence à categoria “medidor de satélite” (Duan et al., 2016).

Outra abordagem alternativa para obter estimativas globais de precipitação é a de dados de reanálise baseados em modelos meteorológicos e numéricos que usam técnicas de assimilação de dados (Xu et al., 2022). ERA5-Land é um conjunto de dados de reanálise climática de quinta geração produzido pelo Centro Europeu de Previsões Meteorológicas de Médio Prazo (ECMWF) que se baseia no ERA5 com ajustes de temperatura orográfica termodinâmica (Muñoz Sabater, 2019). TerraClimate é um conjunto de dados produzido pela combinação de climatologia espacial do WorldClim com informações variáveis no tempo da Climate Research Unit (CRU Ts4.0) (Abatzoglou et al., 2018).

Muitos estudos foram realizados para avaliar produtos de precipitação em escalas global, continental e regional (Duan et al., 2016; Prakash, 2019; Tan et al., 2020; Dubey et al., 2021; Xu et al., 2022). Vários estudos de avaliação foram realizados no Brasil. Por exemplo, Oliveira et al. (2018) avaliaram as características e a incerteza do IMERG sobre a Região Amazônica Central. Gadelha et al. (2019) avaliaram o IMERG sobre o Brasil no nível da grade em várias escalas de tempo e espaço para o período entre janeiro e dezembro de 2016. Freitas et al. (2020) avaliaram a capacidade do IMERG em definir eventos de precipitação sub-diários e suas propriedades por um período de três anos (2015–2017). Melo et al. (2015) avaliaram as estimativas de desempenho pluviométrico TRMM 3B42V6 e V7 do Brasil. Mu et al. (2021) compararam a precisão de três produtos de precipitação baseados em satélite de 1981 a 2019 sobre o estado de Rondônia, na Amazônia brasileira, e Paredes-Trejo et al. (2017) validaram o

produto de precipitação CHIRPS em escala mensal para 1981–2013 no NEB. Brito et al. (2022) avaliaram dois produtos de precipitação para estimar precipitação e erosividade, incluindo CHIRPS, em uma bacia semiárida brasileira. Brito et al. (2021) analisaram seca meteorológica com produtos de precipitação (incluindo CHIRPS), em uma bacia semiárida brasileira.

A Tabela 1 fornece uma revisão tabular da literatura que mostra alguns estudos relevantes que avaliam diferentes produtos de precipitação em escalas continentais e regionais.

Tabela 1 – Resumo dos estudos relevantes que avaliam diferentes produtos de precipitação em escalas continental e regional

Study	Precipitation Products	Timescale	Location/study area	Study period	Analysis approach
Duan et al. (2016)	TRMM, CMORPH_RAW, CMORPH_CRT, CMORPH_BLD, PCDR, PGF, CHIRPS, GSMaP_MVK	Daily, monthly, annual	Adige Basin-Italy/ 0.012 M km ²	2000–2010	Grid box
Prakash (2019)	CHIRPS, MSWEP, SM2RAIN-CCI, TRMM	Monthly	India/3.3M km ²	1998–2015	Grid box
Xu et al. (2022)	IMERG, GSMaP, ERA5, ERA5-Land	Hour, daily, annual	China/9.3 M km ²	2016–2019	Point-cell and grid box
Gadelha et al. (2019)	IMERG	Daily, monthly, annual	Brazil/8.5 M km ²	2016	Grid box
Melo et al. (2015)	TRMM	Daily, monthly	Brazil/8.5 M km ²	1998–2011	Grid box
Mu et al. (2021)	CHIRP, CHIRPS	Monthly	Rondônia-Brazil/ 0.24 M km ²	1981–2019	Point-cell
Paredes-Trejo et al. (2017)	CHIRPS	Monthly	Northeast Brazil/ 1.56 M km ²	1981–2013	Point-cell
This study	CHIRPS, IMERG, TRMM, ERA5-Land, TerraClimate	Monthly, annual	Northeast Brazil/ 1.56 M km ²	2001–2019	Grid box

Fonte: O Autor (2024).

Os produtos de precipitação TRMM, IMERG, CHIRPS, TerraClimate e ERA5-Land estão atualmente disponíveis no *Google Earth Engine* (GEE). GEE é uma plataforma de processamento geoespacial baseada em nuvem lançada pelo Google em 2010, que compila trilhões de medições científicas (incluindo observações meteorológicas como precipitação, temperatura e velocidade do vento) (Gorelick et al., 2017). As principais vantagens do GEE são sua notável capacidade de processamento e aplicação em larga escala (Tamiminia et al., 2020). Dados os vários produtos de precipitação disponíveis, é essencial comparar cada um com as observações de campo disponíveis para a sua utilização e aplicabilidade mais amplas (Dubey et al., 2021). Isto pode ser especialmente benéfico para algumas áreas com poucos dados terrestres no NEB e outras regiões da América do Sul e África (Sampson et al., 2014; Xavier et al., 2016; Kidd et al., 2017; Brocca et al., 2020). O NEB é uma região ideal para avaliar a precisão dos produtos de precipitação, considerando sua cobertura espacial e diversas características hidrogeoclimatológicas com três zonas climáticas (tropical, semiárido e subtropical úmido) e quatro biomas (Amazônia, Cerrado, Caatinga e Mata Atlântica).


Além disso, uma avaliação abrangente desses produtos de precipitação em escalas espaciais e temporais distintas é essencial para sua aplicação prática e serve de referência para gestores e pesquisadores selecionarem o produto ideal para a aplicação pretendida e suas incertezas associadas. A avaliação abrangente dos produtos de precipitação aqui relatada servirá como referência para gestores e pesquisadores selecionarem o produto ideal para a aplicação pretendida e as incertezas associadas. Considerando as lacunas em estudos anteriores no Brasil, até onde sabemos, este é o primeiro estudo que avalia cinco produtos de precipitação em diferentes escalas espaciais e sazonais ao longo de dezenove anos em diferentes biomas NEB. Este estudo fornece insights sobre o desempenho dos produtos de precipitação no NEB. Portanto, as principais questões abordadas neste estudo são as seguintes: (a) Os produtos de precipitação apresentam desempenho semelhante? (b) A qualidade dos dados dos produtos de precipitação é semelhante em diferentes períodos sazonais? (c) O desempenho dos dados dos produtos de precipitação varia espacialmente? (d) A qualidade dos dados dos produtos de precipitação varia em diferentes escalas de tempo? Os resultados obtidos informarão os utilizadores sobre os pontos fortes e fracos destes produtos e ajudarão a selecionar o conjunto de dados apropriado com base nas suas respectivas aplicações.

2.2 MÉTODOS E DADOS

2.2.1 Área de estudo

O NEB está localizado no extremo leste da América do Sul, entre 1° e 18° S e 35° e 47° W (Fig. 2). A região apresenta acentuada variabilidade pluviométrica interanual, com alguns anos sendo extremamente secos e outros extremamente chuvosos. Além disso, a precipitação na região varia entre 250 e 2000 mm (Martins et al., 2019; et al., 2020) (Fig. 2 B). Na Fig. 2A, é possível visualizar as três zonas climáticas que compõem a região: tropical (Zona A), semiárida (Zona B) e subtropical úmida (Zona C) (Alvares et al., 2013). Também é possível observar que o período chuvoso ocorre em meses diferentes em três sub-regiões: janeiro a junho na Região 1 (R1), março a agosto na Região 2 (R2) e novembro a abril na Região 3 (R3) (adaptado de Lucena et al., 2011; Cunha et al., 2015; Costa et al., 2020).

Figura 2 – Localização do NEB. A) Classificação climática de Köppen para o NEB (de acordo com Alvares et al., 2013; A, B e C representam as zonas climáticas Tropical, Semiárida e Subtropical Úmida, respectivamente) e R1, R2 e R3 são sub-regiões definidas pelo período chuvoso (contornos amarelos; adaptado de Lucena et al, 2011; Cunha et al., 2015; Costa et al., 2020), B) localização dos biomas presentes no NEB e distribuições espaciais da precipitação média anual (mm) entre 2001-2019 (Xavier et al., 2022)



Fonte: O Autor (2024).

Quatro biomas principais são encontrados no NEB: Amazônia, Cerrado, Caatinga e Mata Atlântica (Fig. 2 B). O bioma Amazônia consiste em uma densa floresta tropical com precipitação média anual de 2300 mm e uma curta estação seca (Mu et al., 2021). O bioma Cerrado é caracterizado por florestas e savanas com estações seca e chuvosa bem definidas com faixas de precipitação anual de 600 mm a 2000 mm (Sano et al., 2019 ; Tonello et al., 2021). A Mata Atlântica é caracterizada por florestas úmidas em áreas costeiras e florestas semidecíduas em áreas continentais com estações chuvosa e seca bem definidas com precipitação anual (aproximadamente de 800 a 4000 mm) (Duarte et al., 2014; Santana et al., 2020). Por fim, o bioma Caatinga, o maior bioma do NEB, é uma região semiárida com vegetação herbácea e arbórea e apresenta os menores valores de precipitação anual com uma estação seca severa, onde aproximadamente 70% da precipitação anual ocorre de fevereiro a abril (Almagro et al., 2020; Andrade et al., 2021), sendo a precipitação um fator limitante da dinâmica fenológica da vegetação (Medeiros et al., 2022). A precipitação neste bioma Caatinga é extremamente irregular, com precipitação anual de 240 a 1500 mm (Beuchle et al., 2015). A força da variabilidade da precipitação do NEB depende da localização e magnitude das anomalias da Temperatura da Superfície do Mar (TSM) no Pacífico e no Atlântico. As anomalias de precipitação do NEB estão ligadas a alguns modos de variabilidade natural, incluindo *El Niño* Oscilação Sul (ENSO), Oscilação Decadal do Pacífico (ODP) e Oscilação Multidecadal do Atlântico (AMO) (Rodrigues e McPhaden, 2014; Barbosa; Kumar, 2016); portanto, mudanças no regime de precipitação no NEB são provavelmente causadas por variações nesses modos.

2.2.2 Conjuntos de dados de precipitação

2.2.2.1 Precipitação observada

O produto de precipitação em grade derivado de pluviômetros com resolução espacial de 0,1° para o Brasil (Xavier et al., 2022) foi usado como conjunto de dados de referência, ou seja, precipitação observada, para comparar os produtos de precipitação. Este conjunto de dados de precipitação diária utilizou dados de precipitação observados derivados de aproximadamente 11.473 pluviômetros da Agência Nacional de Águas e Saneamento Básico (ANA) e do Instituto Nacional de Meteorologia (INMET) de janeiro de 1961 a julho de 2020. O método *Angular Distance Weighting* (ADW) foi usado para gerar os dados de precipitação observados em grade. A precipitação observada está disponível em <https://sites.google.com/site/alexandrecandidoxavierufes/brazilian-daily-weather-gridded-data?authuser=0>.

2.2.2.2 Produtos de precipitação

Cinco produtos de precipitação do CHIRPS, ERA5-Land, TerraClimate, IMERG e TRMM para 2001–2019, com base no período de disponibilidade comum de cada conjunto de dados de precipitação, foram utilizados neste estudo (Tabela 2). Os dados dos produtos de precipitação de satélite e modelos foram obtidos utilizando a plataforma GEE (Gorelick et al., 2017).

Tabela 2 – Resumo dos produtos baseados em satélite que fornecem dados diários e mensais em escala global sobre o GEE

Product	Version	Spatial Resolution	Temporal Resolution	Period
CHIRPS	CHIRPS v.2	0.05°	Daily	1981 – Present
ERA5-Land	ERA5-LAND v.5	0.1°	Daily/Monthly	1981– Present
TRMM	TRMM_3B43 v.7	0.25°	Sub-daily/ Daily/Monthly	1998 – 2019
IMERG	IMERG v.6	0.1°	Sub-daily/ Daily/Monthly	2000 – Present
TerraClimate	TerraClimate v.2	0.04°	Monthly	1958 – Present

Fonte: O Autor (2024).

O CHIRPS é um conjunto de dados de precipitação de longo prazo quase global (50° S–50° N) desenvolvido pelo *United States Geological Survey* (USGS) e pelo *Climate Hazards Group* (CHG) para analisar tendências e monitorar secas sazonais (Funk et al., 2015). O CHIRPS incorpora imagens de satélite de resolução de 0,05° com dados de estação in situ para criar uma série temporal de precipitação em grade para esses propósitos (Funk et al., 2015). Os principais conjuntos de dados usados para a construção do produto CHIRPS incluem (i) dados de estações pluviométricas de várias fontes, (ii) climatologia pluviométrica mensal (CHPelim), que usa estações pluviométricas coletadas da FAO e GHCN; (iii) informações de duração da nuvem fria (CCD) baseadas em dados arquivados de infravermelho térmico (TIR) do CPC e do *NOAA National Climate Data Center* (NCDC), que considera a duração da nuvem fria, que é o intervalo de tempo em que um pixel de temperatura está abaixo de um certo limite, e (iv) dados

da versão 7 TRMM 3B42 (Duan et., 2016; Dembélé; Zwart, 2016). Este conjunto de dados tem sido usado em vários estudos científicos (Luo et al., 2019; Hurtado et al., 2021; Mokhtari et al., 2022).

ERA5-Land é um conjunto de dados de reanálise que fornece uma visão consistente da evolução das variáveis do solo ao longo de várias décadas com uma resolução melhorada em comparação com a do ERA5. O ERA5-Land foi produzido a partir do componente terrestre de reanálise climática ERA5 do ECMWF com uma resolução espacial de 0,1° (Muñoz Sabater, 2019). A reanálise combina dados de modelos de observações mundiais em um conjunto de dados globalmente completo e consistente usando as leis da física (Muñoz Sabater, 2019). O ERA5-Land usa como entrada as variáveis atmosféricas do ERA5. A temperatura do ar de entrada, a umidade do ar e a pressão usadas com o ERA5-Land foram corrigidas para levar em conta a diferença de altitude e a grade de maior resolução do ERA5-Land (Muñoz Sabater, 2019). A resolução espaço-temporal fina do ERA5-Land torna este conjunto de dados útil para todos os tipos de aplicações de superfície do solo (Xu et al., 2022; Longo-Minnolo et al., 2022; Nazeer et al., 2022).

TerraClimate é um conjunto de dados climáticos mensais e balanço hídrico climático para superfícies terrestres globais com resolução espacial de 0,04°, produzido pela combinação de dados de resolução grosseira de variação temporal da *Climate Research Unit* (CRU Ts4.0) e da Reanálise Japonesa de 55 anos (JRA55) (Abatzoglou et al., 2018). Este conjunto de dados usa interpolação assistida pelo clima, combinando normais climatológicas de alta resolução espacial do conjunto de dados WorldClim com uma resolução temporal mais grosseira. O TerraClimate produz um conjunto de dados mensais de precipitação, temperaturas máximas e mínimas, velocidade do vento, pressão de vapor e radiação solar (Abatzoglou et al., 2018). Muitos estudos usaram este conjunto de dados para várias aplicações (Abdi, 2019; Ahamed et al., 2022).

O TRMM foi lançado pela Administração Nacional de Aeronáutica e Espaço dos EUA e pela Agência de Exploração Aeroespacial do Japão para monitorar a precipitação tropical e subtropical (Arshad et al., 2021). O TRMM mescla dados de micro-ondas de vários satélites. O algoritmo 3B43 é executado uma vez por mês para produzir a melhor estimativa única de taxa de precipitação e campo de estimativa de erro de precipitação, combinando estimativa de alta qualidade com precipitação global cumulativa mensal do Centro Global de Climatologia de Precipitação (GPCC) (TRMM - TROPICAL RAINFALL MEASURING MISSION, 2017). A missão TRMM terminou em abril de 2015.

O *Global Precipitation Measurement* (GPM)-IMERG fornece observações de próxima geração de chuva e neve a cada 3 horas com uma resolução espacial de $0,1^\circ$. IMERG é o algoritmo unificado que fornece estimativas de precipitação combinando dados de todos os instrumentos passivos de micro-ondas (PM) na constelação GPM. Sensores (PM) em satélites em órbita polar podem penetrar nas nuvens para explorar suas propriedades e identificar partículas de precipitação dispersas devido a grandes partículas de gelo (Dembélé; Zwart, 2016; Paredes-Trejo et al., 2017). Em geral, o PM é utilizado para estimar a quantidade de chuva devido ao aumento da relação física direta entre o sinal do sensor e a precipitação (Dembélé; Zwart, 2016). O algoritmo IMERG destina-se a calibrar, mesclar e interpolar todas as estimativas de PM de satélite junto com estimativas de satélite infravermelho (IR) calibradas por micro-ondas, análises de medidores de precipitação e outros estimadores de precipitação com escalas precisas de tempo e resolução espacial para as áreas TRMM e GPM em o globo (Huffman et al., 2019).

2.2.3 Estatísticas de validação

A avaliação de desempenho foi conduzida para os períodos comuns de sobreposição das diferentes fontes de 2001 a 2019, totalizando 19 anos de análise para NEB. Os produtos de precipitação e reanálise do satélite têm diferentes resoluções espaciais variando de $0,04^\circ$ a $0,25^\circ$, então eles foram reamostrados para a resolução espacial observada de precipitação em uma grade ($0,1^\circ$). Além disso, como estão em diferentes resoluções temporais (diária e mensal), os produtos com dados diários de precipitação foram acumulados para produzir informações mensais e padronizar a resolução temporal para a escala mensal.

Para uma avaliação detalhada dos produtos de precipitação com dados de precipitação observados, e considerando que uma única métrica fornece apenas uma projeção de um certo aspecto dos erros característicos (Ferreira et al., 2020), quatro métricas estatísticas contínuas, ou seja, viés percentual (PBIAS), coeficiente de correlação de Pearson (r), erro quadrático médio (RMSE) e erro quadrático médio relativo (RRMSE), foram calculadas para cada ponto da grade (12854 no NEB) para o período de estudo. O PBIAS mede a tendência média dos valores estimados, que podem ser maiores ou menores do que os observados, com um valor ótimo de 0. O coeficiente r de Pearson mede a força da relação linear entre estimativas e observações, variando de -1 a 1, com uma pontuação perfeita de 1. O RMSE fornece informações sobre a estimativa do erro e a magnitude média das estimativas do erro [mm.mês-

1], e o RRMSE é calculado dividindo o RMSE com dados de observação médios. Ambos têm valores ideais próximos de zero. O PBIAS mede a tendência média dos valores estimados, que podem ser maiores ou menores do que os observados, com um valor ótimo de 0. As equações, intervalos de valores e valores perfeitos das métricas estatísticas mencionadas estão listados na Tabela 3.

Tabela 3 – Lista de métricas estatísticas para avaliação dos produtos de precipitação

Metrics names	Equations	Value Range	Perfect Values
Percent bias (PBIAS)	$PBIAS = \frac{\sum_1^n (Si - Gi) \cdot 100}{\sum_1^n Gi}$	$] -\infty, \infty[$	0
Pearson's correlation coefficient (r)	$r = \frac{\sum_1^n (Si - S) \cdot (Gi - G)}{\sqrt{\sum_1^n (Si - S)^2 \cdot \sum_1^n (Gi - G)^2}}$	$[-1, 1]$	1
Root mean square error (RMSE)	$RMSE = \left(\frac{\sum_{i=1}^n (Si - Gi)^2}{n} \right)^{0.5}$	$[0, +\infty[$	0
Relative root mean square error (RRMSE)	$RRMSE = \frac{RMSE \cdot 100}{G}$	$[0, +\infty[$	0

Nota: Si é a precipitação estimada a partir dos produtos avaliados, Gi é a precipitação observada, S e G são suas respectivas médias e n é o número de observações.

Fonte: O Autor (2024).

2.2.4 Análise espacial e sazonal


Usando o período entre 2001 e 2019 a partir de dados de precipitação observados e produtos de precipitação, avaliamos padrões espaciais e de todo o bioma usando as métricas descritas na seção 2.3. Para isso, realizamos as análises nas seguintes escalas: (i) mensal: avalia os produtos de cada mês da série histórica em escala mensal, (ii) sazonal: avalia o desempenho dos produtos por mês do ano (janeiro, fevereiro, março, abril, maio, junho, julho, agosto, setembro, outubro, novembro e dezembro) e (iii) anual: avalia a precipitação total anual para cada ponto da grade sobre o NEB.

2.3 RESULTADOS

2.3.1 Análise espacial em escala mensal

A Figura 3 mostra as distribuições espaciais das métricas estatísticas de precipitação mensal ao longo de 19 anos de dados NEB derivados dos cinco produtos de precipitação e precipitação observada e a média e desvio padrão (dp) dos valores PBIAS, r , RMSE e RRMSE do NEB são fornecidos para cada produto de precipitação (Tabela 4), os valores das métricas estatísticas foram arredondados para os dois dígitos decimais mais próximos.

Figura 3 – Distribuições espaciais de A) PBIAS, B) r , C) RMSE e D) RRMSE da precipitação mensal do CHIRPS, ERA5-Land, IMERG, TerraClimate e TRMM em comparação com a precipitação observada para o período 2001-2019 no NEB. Os valores médios de PBIAS, r , RMSE e RRMSE também são fornecidos para cada produto de precipitação



Fonte: O Autor (2024).

O IMERG, CHIRPS e TRMM apresentaram os maiores valores de r (0,93), enquanto TerraClimate e ERA5-Land revelaram o menor valor (0,89). No geral, o ERA5-Land subestimou a precipitação com um valor PBIAS de -2,61%, enquanto CHIRPS, IMERG, TRMM e TerraClimate superestimaram a precipitação com um valor PBIAS variando de 3,53% a 13,35%. Embora o ERA5-Land apresente o melhor valor médio de PBIAS (-2,61), é aquele que oferece o maior valor de dp (+17,4), indicando maior variabilidade nos valores registrados; isso pode ser observado na Figura 3, que mostra o contraste entre a região leste do NEB que tende a subestimar a precipitação e a porção oeste que apresenta maior tendência a superestimar. O valor RMSE variou de 29,63 mm/mês (CHIRPS) a 41,61 mm/mês (TerraClimate); os maiores valores foram registrados no litoral e porção noroeste do NEB. O valor do RRMSE variou de 42,28% a 58,16%, sendo que os maiores valores foram registrados na porção central NEB. Os produtos baseados em satélite (CHIRPS, IMERG e TRMM) tiveram desempenho semelhante e geralmente superaram os produtos baseados em modelos (TerraClimate e ERA5-Land). Portanto, três destes produtos (CHIRPS, IMERG e TRMM) podem razoavelmente ser considerados os principais produtos para estimar a precipitação total mensal.

Tabela 4 – Resumo da média e do desvio padrão (sd) das estatísticas descritivas da precipitação mensal no NEB. Os melhores valores são mostrados em negrito

Product	Validation statistics			
	PBIAS(%)	r	RMSE (mm/month)	RRMSE(%)
CHIRPS	3.53+-10.60	0.93+-0.05	29.63+- 9.17	42.28+-12.80
ERA5-Land	-2.61+-17.40	0.89+-0.05	38.82+- 12.0	54.84+-15.60
IMERG	13.4+-15.4	0.94+-0.03	31.69+- 8.49	45.79+-15.70
TerraClimate	3.00+-11.90	0.86+-0.07	41.61+- 15.6	58.16+-15.80
TRMM	10.85+-13.90	0.93+-0.03	32.72+- 9.37	46.67+-13.70


Fonte: O Autor (2024).

2.3.2 Análise sazonal

Para avaliar o desempenho das estimativas de precipitação derivadas desses produtos de precipitação no contexto sazonal, os valores das métricas numéricas por mês no período de

2001–2019 no NEB são ilustrados na Fig. 4. Os menores valores de RMSE foram registrados de julho a outubro, com valores maiores que 25 mm/mês (Fig. 4), porém neste período foram registrados os maiores valores de (RRMSE). Além disso, durante este período, foi evidenciada uma tendência de subestimação nos valores de precipitação estimados pelos satélites com valores de PBIAS menores que zero. De fevereiro a maio, houve um aumento no valor de RMSE (>40 mm/mês), e os valores de PBIAS se aproximaram de 0. Em geral, os valores de r foram altos, com valores acima de 0,7 para a maioria dos meses. Além disso, janeiro foi claramente o mês com o maior valor, enquanto os valores de r para junho, julho e agosto apresentaram bom desempenho (Fig. 4).


Figura 4 – Boxplots das métricas de desempenho A) PBIAS, B) r , C) RMSE e D) RRMSE para cada mês de 2001 a 2019 para os produtos de precipitação (CHIRPS, ERA5-Land, IMERG, TerraClimate e TRMM) no NEB



Fonte: O Autor (2024).

A Figura 5 apresenta as métricas estatísticas de precipitação mensal para as sub-regiões do NEB definidas pelo período chuvoso (Figura 2A). TRMM e IMERG apresentam tendência de superestimação para as regiões R1 e R3, em contraste com os demais produtos (CHIRPS, ERA5-Land e TerraClimate), que revelaram subestimações.

Figura 5 – Valores medianos das métricas de desempenho (PBIAS, r, RMSE e RRMSE) por mês do ano de 2001 a 2019 para os produtos de precipitação (CHIRPS, TRMM, IMERG, ERA5-Land e TerraClimate) para três sub-regiões definidas pelo período chuvoso: (R1) janeiro a junho; (R2) março a agosto; e (R3) novembro a abril (adaptado de Lucena et al., 2011; Cunha et al., 2015; Costa et al., 2020). TERRAC: TerraClimate, ERA5L: ERA5-Land




Fonte: O Autor (2024).

Os valores do PBIAS variaram de -51,75% a 87,4%. A região R2, localizada no litoral do NEB, apresenta tendência de subestimação de todos os produtos durante a maior parte do ano. As estações secas de cada região registram os menores valores de RMSE (<25 mm/mês) e valores de RRMSE > 50%, enquanto valores de RMSE acima de 50 mm/mês são registrados na estação chuvosa e valores de RRMSE < 55%. IMERG, TRMM e CHIRPS registram os valores de r mais altos para as três regiões e, conforme indicado na Fig. 5, os valores de r mais altos são registrados em janeiro para todas as regiões (R1, R2 e R3).

2.3.3 Desempenho por bioma em escala mensal

Nesta seção, os resultados das métricas de desempenho para cada bioma no NEB são apresentados. Para comparação, as métricas de desempenho foram avaliadas usando *Boxplots* (Fig. 6). No geral, os produtos de satélite tendem a subestimar a precipitação para o bioma Mata Atlântica, localizado na costa leste do NEB, com valores medianos de PBIAS variando de aproximadamente -8% (CHIRPS) a -25% (ERA5-Land). Para o bioma Caatinga, o valor mediano de PBIAS variou de 12% a -12%. Os maiores valores de RMSE ocorreram na Amazônia e na Mata Atlântica, enquanto os biomas Cerrado e Caatinga apresentaram os menores valores. Os maiores valores de RRMSE ocorreram para Caatinga e Mata Atlântica. O bioma Amazônia apresentou o maior valor de r , com valores medianos de 0,87 a 0,95, e os pluviômetros localizados na Mata Atlântica apresentaram valores medianos de 0,82 a 0,90. Em contraste, os biomas Caatinga e Cerrado apresentaram valores acima de 0,80 na maioria dos pontos da grade.


Figura 6 – Boxplot das métricas A) PBIAS, B) r , C) RMSE e D) RRMSE dos produtos CHIRPS, TRMM, IMERG, ERA5-Land e TerraClimate para cada bioma do NEB (Amazônia, Caatinga, Cerrado e Mata Atlântica) para precipitação mensal



Fonte: O Autor (2024).

Para fornecer mais informações sobre o comportamento dos produtos satélites, foi realizada uma comparação entre as séries temporais de precipitação média mensal da precipitação observada e os produtos CHIRPS, TRMM, IMERG, ERA5-Land e TerraClimate sobre cada bioma do NEB (Amazônia, Caatinga, Cerrado e Mata Atlântica) (Fig. 7). Em geral, os produtos conseguiram captar adequadamente a variabilidade da precipitação no NEB e apresentar boa correspondência com o produto de precipitação baseado nos pluviômetros. Porém, mostra-se a tendência do TerraClimate em superestimar a precipitação no bioma Amazônia, principalmente durante o período chuvoso e o ERA5-Land em subestimar a precipitação no bioma Mata Atlântica.

Figura 7– Precipitação média mensal derivada da precipitação observada e dos produtos CHIRPS, TRMM, IMERG, ERA5-Land e TerraClimate em cada bioma do NEB: A) Amazônia, B) Mata Atlântica, C) Caatinga e D) Cerrado para o período de 2001-2019




Fonte: O Autor (2024).

2.3.4 Avaliação à escala anual

Os dados de precipitação total mensal foram ainda acumulados para a precipitação total anual. As distribuições espaciais das métricas estatísticas dos dados de precipitação anual para todos os produtos de precipitação são representadas graficamente na Figura 8. Globalmente, nesta escala de tempo, houve uma redução nos valores de r para todos os produtos com valores inferiores a 0,84. Sobre o PBIAS, as métricas não mudaram significativamente. Como esperado, os valores do RMSE aumentaram na escala anual; no entanto, registou-se uma redução nos valores do RRMSE comparativamente à escala mensal (<22%). Assim como na escala mensal, CHIRPS, IMERG e TRMM apresentaram as melhores métricas de desempenho.


Figura 8 – Distribuições espaciais de A)PBIAS, B) r, C)RMSE e D)RRMSE da precipitação anual do CHIRPS, ERA5-Land, IMERG, TerraClimate e TRMM em comparação com a precipitação observada para o período de 2001 a 2019 no NEB



Fonte: O Autor (2024).

Apresentamos os resultados das métricas de desempenho para cada bioma no NEB para precipitação anual. Para comparação, as métricas de desempenho foram avaliadas usando boxplots (Fig. 9). De modo geral, o bioma Mata Atlântica apresentou as piores métricas de desempenho. Os valores de r foram menores em todos os biomas em comparação à escala mensal. Os maiores erros relativos (RRMSE) foram registrados para os biomas Mata Atlântica e Caatinga.


Figura 9 – Boxplot das métricas A) PBIAS, B) r , C) RMSE e D) RRMSE dos produtos CHIRPS, ERA5-Land, IMERG, TerraClimate e TRMM para cada bioma do NEB (Amazônia, Caatinga, Cerrado e Mata Atlântica) para precipitação anual



Fonte: O Autor (2024).

A Figura 10 mostra o padrão espacial da precipitação média anual sobre o NEB durante 2001-2019 a partir de dados do produto de precipitação observada e dos cinco produtos avaliados na resolução espacial comum de $0,1^\circ$. A partir dos dados interpolados de precipitação, a precipitação média anual variou de 350 mm a 2.300 mm/ano. Como esperado, os maiores valores foram registrados para o bioma Amazônia e os menores para a Caatinga. No geral, todos os produtos capturaram os padrões de distribuição da precipitação no NEB. Porém, em algumas regiões do NEB, fica evidente a dificuldade dos produtos em reproduzir adequadamente a magnitude da precipitação com tendência a superestimar e subestimar o que está ocorrendo nas diferentes localidades. Por exemplo, o litoral leste do NEB apresenta tendência a subestimar a precipitação e algumas áreas da Caatinga com tendência a superestimar a precipitação.

Figura 10 – Distribuição espacial da precipitação média anual para o período 2001-2019 a partir da precipitação observada e dos produtos de precipitação (CHIRPS, ERA5-Land, IMERG, TerraClimate e TRMM)



Fonte: O Autor (2024).

2.4 DISCUSSÃO

O presente trabalho contribui para aumentar o conhecimento do uso de produtos de precipitação derivados de satélites no NEB em escalas espaciais e sazonais. No geral, IMERG, TRMM e CHIRPS exibiram as melhores métricas de desempenho. Uma possível explicação para o porquê de CHIRPS e IMERG superarem ERA5-Land e TerraClimate é que esses produtos de precipitação de satélite passam por uma calibração do solo (Lopez, 2011; Hersbach et al., 2020; Abatzoglou et al., 2018; Xu et al., 2022). O CHIRPS usa dados TRMM para calibrar estimativas globais de precipitação de duração de nuvem fria, o que pode explicar os desempenhos semelhantes desses três produtos (CHIRPS, IMERG e TRMM) (Funk et al., 2015; Katsanos et al., 2016). Isso é geralmente consistente com estudos anteriores (Melo et al., 2015; Paredes-Trejo et al., 2017; Gadelha et al., 2019; Pedreira Junior et al., 2021) nos quais TRMM 3B42, IMERG e CHIRPS foram bem adaptados para representar a variabilidade da precipitação, exceto na região mais próxima da costa leste (bioma Mata Atlântica), onde o produto teve as métricas mais pobres. Isso pode ser explicado pela presença de nuvens quentes

comuns na costa leste do NEB que contribuem para uma maior deficiência nas estimativas de precipitação por satélite (Melo et al., 2015 ; Gadelha et al., 2019; Freitas et al., 2020; Pedreira Junior et al., 2021). Rozante et al. (2018) detectaram uma forte subestimação para a região costeira brasileira ao analisar os produtos IMERG e TRMM. Rodrigues et al. (2021) indicaram que uma possível explicação para essa subestimação na costa leste do NEB é o tipo de sistema climático impulsionado pela zona de convergência intertropical com a presença de nuvens quentes. Nuvens quentes têm pouco desenvolvimento vertical e baixo teor de gelo, dificultando a estimativa da precipitação usando satélites (Hobouchian et al., 2017). Aproximadamente 50% das nuvens precipitantes no NEB não contêm gelo em sua estrutura, e sensores passivos de micro-ondas não conseguem detectá-los com eficiência; no entanto, sensores ativos de micro-ondas podem penetrar nas nuvens e são mais eficazes (Palharini; Vila, 2017).

Além disso, as diferenças entre os produtos de precipitação avaliados e a precipitação observada podem ser atribuídas a vários fatores, incluindo erros na amostragem de satélite, algoritmos para estimar a precipitação de plataformas individuais, erros em algoritmos para misturar estimativas individuais e medições de estações pluviométricas (Shen et al., 2010). Em geral, a quantidade de precipitação atual que atinge o solo é geralmente maior do que a medida em pluviômetros (Dahri et al., 2018); isso é explicado devido a erros de medição que afetam os pluviômetros, como exposição a altas temperaturas e ventos predominantes e a topografia e vegetação ao redor do pluviômetro. Os pluviômetros podem subestimar a precipitação em até 25%–30% em condições de chuva forte e vento (Schleiss et al., 2020; Pollock et al., 2018). A subestimação de precipitação induzida pelo vento e de alta temperatura sobre o NEB pode ser a fonte dominante de erros nas observações do pluviômetro. Uma das fontes comuns de erros e incertezas em produtos de precipitação por satélite são os bancos de dados a priori de perfis de nuvens e precipitação; na ausência de observações de radar sobre o continente, esses bancos de dados a priori para recuperar estimativas passivas de precipitação por satélite baseadas em micro-ondas não são robustos o suficiente (Xu et al., 2022). A evaporação de hidrometeoros da base da nuvem também é um aspecto ignorado pelos produtos de precipitação por satélite (Dubey et al., 2021). Além disso, as emissividades de fundo da superfície do solo que dependem de fatores como clima, vegetação e terreno desempenham o papel mais crítico na incerteza da estimativa de precipitação por satélite (Maggioni et al., 2014).

Os produtos de precipitação capturaram a sazonalidade da precipitação para os diferentes biomas NEB. Os cinco produtos tenderam a apresentar os erros mais elevados (RMSE) durante os meses mais chuvosos (dezembro a abril), o que pode ser explicado pela

coincidência da estação chuvosa nas três sub-regiões (Fig. 2A). Oliveira et al. (2017) identificaram maiores precipitações nos meses de março e abril no norte, entre dezembro e março no sudoeste, e entre abril e julho no litoral leste do NEB. Os biomas Amazônia e Mata Atlântica apresentaram os maiores valores de RMSE. Isso pode ser explicado pelo maior volume de água precipitada nesses biomas. Nessas regiões, a precipitação média anual é superior a 1.200 mm, diferentemente dos pluviômetros dos biomas Caatinga e Cerrado, que registram precipitação média anual acumulada inferior a 800 mm (Alvares et al., 2013). Ao avaliar as métricas r e RRMSE, os meses chuvosos apresentam melhor desempenho. Houve redução no valor de r na escala anual e os valores de PBIAS não se alteraram significativamente. Isto indica que os erros mensais de precipitação não foram aleatórios, mas são caracterizados por um viés positivo ou negativo (Duan et., 2016). O bioma Amazônia do NEB apresentou excelente correspondência entre dados de satélite e dados observados porque as estimativas de precipitação por sensoriamento remoto assimilam uma maior frequência de eventos de alta intensidade (Sun et al., 2018), que é comumente registrado neste bioma. Nas regiões secas, a predominância de nuvens cúmulos rasos e quentes (Costa et al., 2000) frustra a identificação da precipitação por meio de satélites (Paredes-Trejo et al., 2017). Beck et al. (2017) destacaram que os produtos de satélite apresentam maior incerteza em regiões com topografias mais complexas e áridas. Além disso, Paredes-Trejo et al. (2017) destacaram a incapacidade dos satélites em capturar a precipitação orográfica na Bacia Hidrográfica do Rio São Francisco (NEB). Dinku et al. (2011) sugeriram que na região seca a superestimação da precipitação pode ser devido à evaporação subnuvem e na região montanhosa a subestimação pode ser devido ao processo de chuva orográfica quente. Nogueira et al. (2018) indicaram que os dados TRMM e CHIRPS podem ser alternativas aos dados de precipitação observada e podem ser usados para compensar a falta de dados das estações meteorológicas.

2.5 CONCLUSÃO

Neste estudo, conduzimos uma avaliação abrangente das últimas versões de cinco produtos de precipitação em grade (CHIRPS, TRMM, IMERG, ERA5-Land e TerraClimate) no NEB usando precipitação observada de 2001 a 2019. O NEB tem diferentes biomas e condições climáticas; portanto, é um bom representante para avaliar o desempenho desses produtos. Este estudo apresenta uma nova contribuição para a visão global do desempenho de vários produtos de precipitação e serve como referência para gerentes e pesquisadores

selecionarem o produto ideal para sua aplicação pretendida e suas incertezas associadas. A avaliação foi conduzida em escalas mensais, sazonais espaciais e anuais no NEB.

Nossa avaliação descobriu que, considerando todas as métricas de avaliação, CHIRPS, IMERG e TRMM podem ser considerados comparativamente superiores aos outros produtos. TerraClimate e ERA5-Land tiveram o pior desempenho, com um viés para subestimação. Além disso, nossa análise sazonal mostrou que os melhores valores de RRMSE foram registrados durante a estação chuvosa (fevereiro a maio), e janeiro teve o maior valor de r , com médias maiores que 0,8 para todos os produtos. Os resultados sugerem que o desempenho dos produtos de satélite depende das características de cada bioma e do sistema de precipitação. Os resultados indicam que os produtos de precipitação baseados em satélite (CHIRPS, IMERG e TRMM) geralmente superam os produtos de precipitação baseados em modelo (TerraClimate e ERA5-Land). Ambos os produtos baseados em satélite e em modelo tiveram as métricas de desempenho menos eficazes no bioma Mata Atlântica, com uma tendência a subestimar a precipitação.

Este estudo demonstra que os produtos de precipitação contribuem para uma melhor compreensão da variabilidade espacial e temporal da precipitação. Além disso, esta pesquisa serve como referência para a escolha de dados de precipitação de produtos ideais com incertezas associadas e pode dar suporte a estudos de modelagem hidrológica, monitoramento de secas; auxiliar no gerenciamento de recursos hídricos em regiões com escassez de estações pluviométricas e outras aplicações. Finalmente, estudos que avaliem produtos de precipitação em outras escalas de tempo (horária e diária) e durante extremos climáticos são recomendados para pesquisas futuras.

3 EFICIÊNCIA DOS PRODUTOS DE PRECIPITAÇÃO PARA MODELAGEM HIDROLÓGICA UTILIZANDO GRANDE AMOSTRAGEM DE BACIAS HIDROGRÁFICAS TROPICAIS E SUBTROPICAIS

A publicação resultante desse capítulo (Apêndice B) é:

João M. de Andrade, Alfredo Ribeiro Neto, Rodolfo L.B. Nóbrega, Miguel A. Rico-Ramirez, Suzana M.G.L. Montenegro. (2024). Efficiency of global precipitation datasets in tropical and subtropical catchments revealed by large sampling hydrological modelling. **Journal of Hydrology**, 633, 131016, <https://doi.org/10.1016/j.jhydrol.2024.131016>.

Resumo

Produtos de precipitação baseados em satélite e reanálise são amplamente adotados como informações complementares às medições *in situ* para estimar a vazão do rio usando modelagem hidrológica. No entanto, ainda há uma lacuna de pesquisa notável na literatura associada à avaliação da precisão de produtos baseados em satélite ou reanálise em diferentes bacias hidrográficas tropicais e subtropicais em modelagem hidrológica de grande amostragem com análise de sensibilidade. Investigamos a precisão da precipitação, o desempenho do modelo hidrológico e a sensibilidade dos parâmetros relacionados a sete conjuntos de dados de precipitação baseados em produtos de satélite e reanálise, ou seja, CHIRPS, TRMM, GLDAS, IMERG, MERRA-2, PERSIANN-CDR e ERA5 em 714 bacias hidrográficas tropicais e subtropicais contrastantes localizadas no Brasil. Usamos o modelo hidrológico Génie Rural Journalier 4 (GR4J) para simular os processos hidrológicos das diferentes bacias com duas abordagens para a calibração: usando dados de precipitação medidos com base em pluviômetros (abordagem I) ou usando cada produto individual de precipitação de satélite/reanálise (abordagem II) para calibrar os modelos. Os resultados mostraram que os produtos de precipitação tendem a superestimar a precipitação, com exceção de ERA5 e MERRA-2. CHIRPS é o único produto que produz estimativas de precipitação imparciais para a maioria das bacias hidrográficas. A calibração do modelo usando cada produto de precipitação individualmente melhorou o desempenho do modelo hidrológico. CHIRPS, IMERG e MERRA-2 mostraram boa precisão em termos de estimativa de precipitação e desempenho de simulação hidrológica no período de calibração. No período de validação, os melhores produtos em termos de KGE foram CHIRPS, IMERG e TRMM ($KGE > 0,64$). Os erros em produtos de precipitação são melhor compensados por meio de modelagem hidrológica em regiões úmidas. A sensibilidade do parâmetro do modelo varia de acordo com a entrada de precipitação, clima

e aridez da bacia hidrográfica. No geral, todos os sete produtos exibiram seu pior desempenho hidrológico em regiões mais áridas. Este estudo ajuda a melhorar nossa compreensão da resposta da bacia hidrográfica em regiões tropicais e subtropicais, ao mesmo tempo em que fornece insights importantes sobre a confiabilidade dos produtos de precipitação de satélite/reanálise para simulação de vazão. Este estudo é valioso em aplicações hidrometeorológicas, avaliação de mudanças climáticas, recursos hídricos e gestão de desastres, especialmente em regiões com uma densidade relativamente escassa de estações de precipitação.

3.1 INTRODUÇÃO

A precipitação representa o maior fluxo de água terrestre e é uma das variáveis atmosféricas mais importantes em estudos que tratam dos ciclos globais de energia, carbono e água (Baethgen; Goddard, 2013; Toté et al., 2015). No entanto, o monitoramento da precipitação, especialmente em países em desenvolvimento, tem sido impactado pela falta de sistemas de monitoramento, pela alta proporção de dados ausentes e pelas séries temporais de curta duração que tornam a análise confiável de dados de precipitação inviável (Xavier et al., 2016). Por exemplo, em muitas regiões da África e da América do Sul, a densidade das redes de pluviômetros é de aproximadamente uma estação por 100.000 km² (Brocca et al., 2020).

O desenvolvimento da assimilação de dados e da tecnologia de sensoriamento remoto permitiu a produção de conjuntos de dados de precipitação de alta qualidade por satélite e métodos de reanálise (Wang et al., 2020a). Estes produtos oferecem uma oportunidade para aplicar e avaliar a variabilidade tempo-espaco da precipitação em escalas espaciais e temporais contrastantes para aplicações hidrológicas e climáticas (Dembélé; Zwart, 2016; Duan et al., 2016; Brocca et al., 2020). Conjuntos de dados de precipitação baseados em produtos de satélite e de reanálise são amplamente utilizados como informações complementares às medições in situ para estimar a vazão fluvial usando modelagem hidrológica (Khatakho et al., 2021; Su et al., 2021). O desempenho desses conjuntos de dados depende da região (Maggioni; Massari, 2018, Wang et al., 2020a, Dubey et al., 2021; Xu et al., 2022) porque estão sujeitos a erros, como os causados por fatores climáticos (Maggioni et al., 2016), uma variedade de condições de superfície (Bytheway; Kummerow, 2010) e o tipo de medição de precipitação (Villarini et al., 2009).

Embora muitos estudos tenham identificado erros e incertezas relacionados às características ambientais e de medição, apenas alguns estudos avaliaram suas implicações em estimativas de vazão usando modelos hidrológicos (Camici et al., 2018; Wang et al., 2023). Normalmente, neste contexto, os estudos em hidrologia abordam uma questão de pesquisa específica para uma realidade local ou avaliam um único produto de precipitação (por exemplo, Li et al., 2012; Yang et al., 2017; Mtibaa; Asano, 2022). Em alguns casos, conjuntos de dados de precipitação baseados em reanálise não são considerados (por exemplo, Jiang; Bauer-Gottwein et al., 2019; Su et al., 2021), ou são referidos apenas a um único estudo de caso específico (por exemplo, Wang et al., 2020a; Moges et al., 2022), ou a um número limitado de bacias hidrográficas (por exemplo, Stephens et al., 2022; Wanzala et al., 2022; Wei et al., 2023; Wu et al., 2023), limitando as possibilidades de análise a um contexto específico e, consequentemente, não podem dar suporte a conclusões gerais.

O Brasil possui a maior quantidade de água doce disponível no mundo (~12%) (Levis et al., 2020; Getirana et al., 2021), e ~20% da água continental global que flui para os oceanos vem de seus rios (Getirana, 2016). Com uma área de ~ 8,5 milhões de km² com diversas características topográficas, de vegetação e de solo distribuídas em três grandes zonas climáticas, ou seja, tropical úmido, subtropical e semiárido, o território brasileiro oferece uma variedade relevante de condições para avaliar produtos de precipitação. A maioria dos estudos no Brasil que avaliaram produtos de precipitação não avaliaram a aplicação desses produtos na modelagem hidrológica (por exemplo, Paredes-Trejo et al., 2017; Cavalcante et al., 2020; Oliveira-Junior et al., 2021; Mu et al., 2021; Ramos Filho et al., 2022). Por exemplo, Melo et al. (2015) avaliaram a precipitação TRMM sobre o Brasil e identificaram baixo desempenho deste produto na região Nordeste, enquanto Gadelha et al. (2019) avaliaram o produto IMERG em diferentes escalas temporais e espaciais e encontraram uma ligeira tendência a superestimar a precipitação terrestre em todas as escalas de tempo. Os estudos envolvendo modelagem hidrológica no Brasil geralmente utilizaram um número limitado de bacias hidrográficas (Falck et al., 2015; Junqueira et al., 2022), e apenas alguns estudos (por exemplo, Almagro et al., 2021b; Reis et al., 2022) usaram várias bacias hidrográficas no Brasil, mas não quantificaram a sensibilidade do modelo hidrológico associado aos produtos de precipitação. Assim, há uma lacuna de pesquisa notável na literatura associada à avaliação da precisão de produtos baseados em satélite ou de reanálise em diferentes bacias hidrográficas tropicais e subtropicais para aplicações hidrológicas.


Até onde sabemos, este é o primeiro estudo que avalia diferentes produtos de precipitação em modelagem hidrológica de grande amostragem com análise de sensibilidade em bacias hidrográficas tropicais e subtropicais com clima, topografia, solo e vegetação contrastantes. O objetivo é apoiar a orientação sobre a aplicação de produtos de precipitação na modelagem hidrológica para potenciais usuários finais em diferentes regiões hidroclimáticas. Isto é conseguido quantificando a precisão dos conjuntos de dados de precipitação com base em produtos de satélite e de reanálise e avaliando o seu desempenho para simular a descarga do rio usando o modelo hidrológico de chuva-escoamento *Génie Rural Journalier 4* (GR4J). Os objetivos são três: i) avaliar a qualidade de sete produtos de precipitação, nomeadamente CHIRPS, TRMM, IMERG, PERSIANN-CDR, MERRA-2; GLDAS e ERA5, estatisticamente, usando a precipitação média da bacia hidrográfica de um produto de grade baseado em pluviômetros; ii) investigar a utilização desses produtos de precipitação em simulações hidrológicas e sua respectiva precisão na estimativa da vazão fluvial, e; (iii) analisar a sensibilidade dos parâmetros do modelo hidrológico a diferentes produtos de precipitação.

3.2 ÁREA DE ESTUDO E CONJUNTOS DE DADOS

3.2.1 Área de estudo

O Brasil possui as principais zonas climáticas tropicais úmidas, subtropicais e semiáridas, conforme definido pela classificação climática de Köppen (Alvares et al., 2013; Fig. 11a); doze regiões hidrográficas (Tabela 5): 1-Atlântico Nordeste (NE) Oriental, 2-Atlântico Leste, 3-Parnaíba, 4-São Francisco, 5-Atlântico NE Ocidental, 6-Tocantins-Araguaia, 7-Paraguai, 8-Atlântico Sudeste, 9-Paraná, 10-Amazônia, 11-Atlântico Sul, 12-Uruguai; e seis biomas: Amazônia, Mata Atlântica, Cerrado, Caatinga, Pampa e Pantanal (Fig. 11). A precipitação média anual para essas regiões varia de ~750 mm/ano no Atlântico NE Oriental, localizado no semiárido, onde os valores potenciais de evapotranspiração são de até ~2.000 mm/ano, na região amazônica. O regime de precipitação no Brasil é altamente sazonal, com exceção das regiões hidrográficas do sul do Brasil que apresentam precipitação uniforme ao longo do ano devido às múltiplas fontes de umidade atmosférica (Chagas et al., 2020).

Figura 11 – Localização e características da região de estudo: a) Classificação climática de Köppen para o Brasil (de acordo com Alvares et al, 2013). b) Mapa de localização contendo as 714 bacias hidrográficas (saídas mostradas por pontos vermelhos) nas quais os produtos de precipitação foram avaliados. Para cada região hidrográfica, a precipitação média de longo prazo da área e o fluxo médio de todas as bacias hidrográficas dentro dela são representados nos subquadros. As áreas sombreadas (cinza) representam a faixa de fluxo diário para as regiões hidrográficas



Fonte: O Autor (2024).

Tabela 5 – Valores médios diários de variáveis climáticas e hidrológicas para as regiões hidrográficas do Brasil

Hydrographic regions	Tmin (C°)	Tmax. (C°)	P (mm/day)	PET (mm/day)	Aridity Index (PET/P)	Runoff (Q) (mm/day)	RC (Q/P)
Eastern NE Atlan.	20.73	30.69	2.10	6.16	2.93	0.19	0.09
East Atlan.	18.74	29.45	2.62	5.49	2.10	0.47	0.18
Parnaíba	21.04	33.15	3.04	6.09	2.00	0.44	0.14
Sao Francisco	17.46	29.74	3.43	5.58	1.63	0.89	0.26
Western NE Atlan.	22.02	32.78	3.78	5.82	1.54	0.63	0.17
Tocantins-Araguaia	19.91	31.68	4.43	5.56	1.26	1.56	0.35
Paraguai	20.52	32.47	4.39	5.46	1.24	1.82	0.42
Southeast Atlan.	16.34	27.18	4.16	4.91	1.18	1.76	0.42
Parana	15.64	27.14	4.36	5.00	1.15	1.78	0.41
Amazon	21.63	32.11	5.56	5.33	0.96	2.06	0.37
South Atlan.	14.20	23.81	4.69	4.42	0.94	2.71	0.58
Uruguai	13.71	24.19	5.04	4.63	0.92	2.75	0.55

Fonte: O Autor (2024).

Observação: os dados são calculados das bacias hidrográficas em uma região hidrográfica usando dados de Almagro et al. (2021a) para o período de 1980 a 2010. O índice de aridez é calculado com base nos valores médios diários de precipitação e evapotranspiração potencial (Arora, 2002). As regiões hidrográficas são classificadas da mais seca (superior) para a mais úmida (inferior) de acordo com o índice de aridez. Temperatura mínima (Tmin); Temperatura máxima (Tmax); Precipitação (P); Evapotranspiração potencial (PET); Coeficiente de escoamento superficial (RC).

3.2.2 Conjunto de dados

3.2.2.1 Precipitação baseada em satélite e reanálise

Sete produtos de precipitação de satélite e reanálise, ou seja, CHIRPS, ERA5, IMERG, GLDAS, MERRA-2, PERSIANN-CDR e TRMM (Tabela 6) foram avaliados. Esses produtos foram escolhidos porque são relatados como consistentes com observações de precipitação

baseadas em pluviômetros (Dubey et al., 2021; Andrade et al., 2022; Wang et al., 2020b; Xu et al., 2022), embora não tenham sido testados usando um modelo hidrológico em diferentes regiões de hidroclimáticas do Brasil. Esses conjuntos de dados foram extraídos usando a plataforma *Google Earth Engine* (GEE) (Gorelick et al., 2017) e sobrepostos nas áreas da bacia hidrográfica para calcular a precipitação média em cada bacia hidrográfica em escala de tempo diária.

Tabela 6 – Cobertura espacial e temporal e resolução dos produtos de precipitação

Dataset (version)	Spatial Resolution	Temporal Resolution	Spatial Coverage	Temporal Coverage	References
CHIRPS (v.2)	0.05°	Daily	50°N–50°S	1981– Present	Funk et al. (2015)
ERA5	0.25°	Hourly	Global	1979– Present	Hersbach et al. (2020)
GLDAS-Noah (v2.1)	0.25°	3 h	Global	2000– Present	Rodell et al., (2004)
IMERG (v.6)	0.10°	Half an hour	50°N–50°S	2000– Present	Huffman et al. (2019)
MERRA-2 PRECTOTCO RR	0.5°×0.625°	Hourly	Global	1980– Present	Gelaro et al. (2017)
PERSIANN- CDR (v.1)	0.25°	Daily	60°N–60°S	1983– Present	Ashouri et al. (2015)
TRMM (3B42 v.7)	0.25°	3 h	50°N–50°S	1998–2019	Huffman et al. (2007)

Fonte: O Autor (2024).

O *Tropical Rainfall Measuring Mission* (TRMM) foi lançada em 1997 e tem sido usada na estimativa de precipitação de alta qualidade para aplicações há quase 20 anos (Huffman et al., 2007; Kidd; Huffman, 2011). O algoritmo 3B43, usado pelo TRMM, calcula a média das estimativas de precipitação de vários satélites em escala mensal e as combina com a análise do medidor de precipitação superficial do *Global Precipitation Climatology Centre* (GPCC) (TRMM, 2017). O *Global Precipitation Measurement* (GPM) foi lançado em 2014 como um sucessor dos serviços TRMM (abrangendo junho de 2000 até o presente), e o *Integrated Multi-satellite Retrievals for GPM* (IMERG) é um algoritmo unificado que fornece estimativas de

precipitação, combinando dados de todos os instrumentos passivos de micro-ondas (PM) na constelação GPM (Kirschbaum et al., 2017, Huffman et al., 2019).

O *Climate Hazards Group InfraRed Precipitation with Station data* (CHIRPS) usa produtos de satélite com dados in situ para gerar séries temporais em grade (Funk et al., 2015). Três tipos de informações são considerados: dados climatológicos globais, estimativas de satélite e medições terrestres e, portanto, enquadram-se na categoria de produto de precipitação “medidor de satélite” (Duan et al., 2016). O *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks - Climate Data Record* (PERSIANN-CDR) é baseada no algoritmo PERSIANN que aplica bandas infravermelhas de satélites geoestacionários (GridSat-B) para estimar a taxa de precipitação e, em seguida, ajustar com o produto mensal do Global Precipitation Climatology Project (GPCP) (Ashouri et al., 2015).

O *European Centre for Medium-Range Weather Forecasts ReAnalysis 5* (ERA5) é a última geração do conjunto de dados de reanálise global produzido pelo *European Centre for Medium-Range Weather Forecasts* (ECMWF) e fornece múltiplas variáveis atmosféricas e de superfície terrestre (Hersbach et al., 2020). A *Modern-Era Retrospective analysis for Research and Applications, Version 2* (MERRA-2) é a versão mais recente da reanálise atmosférica global do *Goddard Earth Observing System Model da NASA, Version 5.12.4* (GEOS-5.12.4) (Gelaro et al., 2017). Usamos o MERRA-2 PRECTOTCORR, no qual um ajuste para viés dependente da latitude é implementado conforme descrito por Reichle et al. (2017). O *Global Land Data Assimilation System Version 2* (GLDAS-2) da NASA utiliza produtos de dados observacionais baseados em satélite e em terrestres usando uma combinação de dados de modelo e observação (Rodell et al., 2004, Wang et al., 2020b). O GLDAS 2.1 incorporou campos de análise atmosférica da *National Oceanic and Atmospheric Administration* (NOAA) / *Global Data Assimilation System* (GDAS) como dados de forçamento (Beaudoin; Rodell, 2020).

3.2.2.2 Vazão, precipitação e evapotranspiração observadas

A vazão diária observada do rio para as bacias hidrográficas brasileiras foi extraída do conjunto de dados *Catchment Attributes for Brazil* (CABra) (Almagro et al., 2021a) derivado do banco de dados da Agência Brasileira de Águas e Saneamento Básico (ANA). O CABra é um grande conjunto de dados de amostra para 735 bacias hidrográficas no Brasil, incluindo mais de 100 atributos de bacias hidrográficas divididos em oito classes principais: topografia, clima, fluxo, águas subterrâneas, solo, geologia, cobertura da terra e perturbação hidrológica,

ou seja, um índice que indica interações humanas que podem modificar os fluxos de água da bacia hidrográfica, para o período hidrológico de 1980–2010.

Uma subseleção de bacias hidrográficas com menos de 10% de dados faltantes para cobrir o período de 2000-2010 foi utilizada, resultando em 714 bacias hidrográficas. O período de 2000-2010 foi utilizado porque é o período durante o qual todos os produtos têm dados disponíveis, começando em 2000 (produtos de precipitação IMERG e GLDAS) e terminando em 2010 (conjunto de dados CABra), esta escolha garante consistência nos dados e facilita a comparação entre os conjuntos de dados de precipitação. Do CABra, extraímos a precipitação de referência, ou seja, a precipitação baseada em pluviômetros (medições de chuva no nível do solo), e a evapotranspiração de referência calculada usando o método Penman-Monteith (Allen et al., 1998). Os dados de precipitação e evapotranspiração terrestres usados no CABra foram extraídos do produto interpolado em grade ($0,25^\circ \times 0,25^\circ$) desenvolvido por Xavier et al. (2016) para todo o território brasileiro. Este conjunto de dados utilizou dados de 2.890 pluviômetros da ANA e do Departamento de Águas e Energia Elétrica do Estado de São Paulo (DAEE), e 735 estações meteorológicas de 1980 a 2013 do Instituto Nacional de Meteorologia (Inmet). Este conjunto de dados foi calculado em média sobre cada bacia hidrográfica em escala de tempo diária.

3.3 METODOLOGIA


O delineamento experimental deste trabalho tem três partes. Na primeira parte, avaliamos a média da precipitação na escala de bacia hidrográfica de sete produtos de comparando com a precipitação em grade baseada em pluviômetros para o período de 2001 a 2010 com uma escala de tempo diária. Na segunda parte, esses produtos de precipitação são usados para conduzir o modelo hidrológico parcimonioso GR4J para avaliar seu desempenho. Duas abordagens foram propostas: (a) abordagem I - um único modelo foi calibrado para cada bacia hidrográfica com dados de precipitação de referência (precipitação baseado em pluviômetros) e validado com os diferentes produtos de precipitação (satélite e reanálise); (b) abordagem II, sete modelos foram calibrados e validados para cada bacia com cada produto de precipitação (satélite e reanálise) individual. Em ambos os casos, os dados foram divididos em três períodos: um período de aquecimento (junho de 2000 a dezembro de 2000), um período de calibração (janeiro de 2001 a dezembro de 2005) e um período de validação (de janeiro de 2006 a setembro de 2010) e o desempenho do modelo é avaliado durante os períodos de calibração e

validação. Por fim, na terceira parte, analisamos a sensibilidade dos parâmetros do modelo hidrológico.

3.3.1 Calibração e validação do modelo hidrológico

Utilizamos o modelo hidrológico GR4J para simular a descarga fluvial porque ele foi aplicado com sucesso em vários estudos em todo o mundo (Wu et al., 2019; Satgé et al., 2021, Tarek et al., 2021; Stephens et al., 2022) devido à sua capacidade de contabilizar as trocas de águas subterrâneas com aquíferos, uma característica distintiva em comparação com modelos conceituais de referência (Hashemi et al., 2022). GR4J é um modelo concentrado que usa evapotranspiração diária (E) e precipitação (P) como entradas (Perrin et al., 2003); a vazão (Q) e a evaporação real (Es) são as saídas, e a umidade do solo no reservatório de produção (S) e no armazenamento de rota (R) são as variáveis de estado do modelo (Nayak et al., 2021). Este modelo utiliza quatro parâmetros, que representam a capacidade máxima do reservatório de produção ($X1$, em mm), o coeficiente de troca de água subterrânea ($X2$, mm), a capacidade máxima para o dia seguinte do reservatório de roteamento ($X3$, em mm) e a base de tempo do hidrograma unitário ($X4$, dia) (Fig. 12) (Perrin et al., 2003; Tegegne et al., 2017).

Figura 12 – Diagrama esquemático do modelo chuva-escoamento GR4J



Fonte: Adaptado de Perrin et al. (2003)

A primeira operação é a subtração da evapotranspiração da precipitação para determinar a precipitação líquida (P_n); se P_n não for zero, uma parte (P_s , a precipitação no nível de S) de P_n preenche o reservatório de produção, é calculado de acordo com o nível S (a quantidade real de armazenamento) (Eq. 1). Se a quantidade de precipitação for menor que a evapotranspiração, a precipitação líquida é igual a 0, e E_s (Eq.2) é calculado como parte da capacidade de evapotranspiração líquida (E_n) (Perrin et al., 2003). A umidade do solo no reservatório de produção é então atualizada (Eq.3). Um vazamento de percolação ($Perc$) (Eq.4) do reservatório de produção é então calculado como uma função de potência do conteúdo do reservatório (Perrin et al., 2003). A percolação da umidade do solo no reservatório de produção e o escoamento direto são adicionados para produzir a quantidade total de água para atingir as funções de roteamento (Pr) (Eq. 5).

Pr é dividido em duas partes fixas. Na primeira parte ($Q9$) (Eq.6), 90 % da Pr (vazão atrasada) é encaminhada através de um hidrograma unitário ($UH1$) com tempo $X4$ baseado em dias, e depois encaminhada por uma capacidade de armazenamento $X3$ de roteamento não linear (Nayak et al., 2021). Na segunda parte ($Q1$) (Eq.7), 10% do Pr (fluxo rápido) é encaminhado por um $UH2$ com base de tempo duas vezes $X4$ ($2.X4$). A quantidade de troca de água subterrânea F entre a bacia e a água subterrânea é calculada usando a Eq. 8, onde R é o nível de armazenamento de rota (Eq. 9), $X3$ é a capacidade de 'referência' e $X2$ é o coeficiente de troca de água, que é positivo quando a água é importada, negativo quando a água é exportada e zero quando não há troca de fluxo (Mohammadi et al., 2022). Q_r e Q_d são os fluxos de saída e de avanço, respectivamente (Eqs. 10 e 11), que são usados para calcular o fluxo total (Q) na saída da bacia hidrográfica (Eq. 12).

A calibração do modelo GR4J e as simulações de escoamento foram realizadas usando o pacote AirGR (Coron et al., 2017; Coron et al., 2018) na linguagem R (R Development Core Team, 2015). Os quatro parâmetros ($X1$, $X2$, $X3$ e $X4$) do modelo GR4J foram calibrados usando o algoritmo de otimização Michel (Michel, 1991), e o coeficiente de eficiência de Nash-Sutcliffe (NSE) (Nash; Sutcliffe, 1970), o indicador mais comum amplamente utilizado em hidrologia (Beck et al., 2017, Stephens et al., 2019), foi selecionado como a função objetivo. Este algoritmo de calibração combina: (i) uma abordagem global para identificar a zona mais provável de convergência e um exame metódico do espaço de parâmetros globais é realizado, e (ii) uma abordagem local, começando com o melhor conjunto de parâmetros da etapa (i), onde uma abordagem de busca local de descida mais íngreme é usada para estimar o conjunto de parâmetros ideal, para estimativa de parâmetros (Michel, 1991; Coron et al., 2018). Este método

necessita de um número menor de execuções de modelo necessárias para convergência (Mathevet et al., 2006) e mostrou eficiência semelhante a algoritmos de busca global mais complexos (Coron et al., 2018).

3.3.2 Métricas estatísticas para avaliar estimativas de precipitação e vazão

Utilizamos as seguintes métricas estatísticas para avaliar o desempenho e a qualidade dos produtos de precipitação em relação ao produto de dados observado (precipitação de referência): erro quadrático médio (RMSE), viés percentual (Pbias) e coeficiente de correlação (r) (Eqs. (13, 14 e 15).

$$RMSE = \left(\frac{\sum_{i=1}^n (Xsim,i - Xobs,i)^2}{n} \right)^{0.5} \quad (13)$$

$$Pbias = \frac{\sum_{i=1}^n (Xsim,i - Xobs,i) \cdot 100}{\sum_{i=1}^n Xobs,i} \quad (14)$$

$$r = \frac{\sum_{i=1}^n (Xsim,i - Xsim) \cdot (Xobs,i - Xobs)}{\sqrt{\sum_{i=1}^n (Xsim,i - Xsim)^2 \cdot \sum_{i=1}^n (Xobs,i - Xobs)^2}} \quad (15)$$

Onde $Xsim,i$ representa a vazão simulada (ou um dado produto de precipitação), $Xobs,i$, representa a vazão observada (ou precipitação), $Xsim$ e $Xobs$ são suas respectivas médias e n é o número de observações. Usamos adicionalmente a métrica de eficiência Kling-Gupta (Eq. 16) para avaliar as estimativas de vazão. Esta métrica é amplamente usada para calibrar e avaliar modelos hidrológicos com dados observados (por exemplo, Mizukami et al., 2019; Brocca et al., 2020; Wanzala et al., 2022). O KGE combina o coeficiente de correlação de Pearson (r), viés e variabilidade, com $\alpha = \frac{\sigma_s}{\sigma_o}$ e $\beta = \frac{\mu_s}{\mu_o}$ onde (μ_o, σ_o) e (μ_s, σ_s) são a média e o desvio padrão das observações e simulações, respectivamente (Gupta et al., 2009). O KGE varia de $-\infty$ a 1 com pontuação perfeita de 1. Valores acima de 0,55 e 0,75 são considerados intermediários e bons, respectivamente, enquanto valores negativos do KGE podem ser considerados “não satisfatórios” (Schönfelder et al., 2022; Brighenti et al., 2019), entretanto, Knoben et al. (2019) observaram que valores de KGE acima de -0,41 representaram desempenho razoável.

$$KGE = 1 - \sqrt{(r - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2} \quad (16)$$

3.3.3 Análise de sensibilidade


A análise de sensibilidade foi conduzida aplicando o método de sensibilidade global de Sobol (Sobol, 1993) usando o pacote *Sensitivity* em R (Iooss et al., 2021) para os parâmetros do modelo GR4J. O NSE modificado (NSE*) foi a função alvo com intervalo $[-1,1]$ (Shin et al., 2013), ele oferece o benefício de mitigar o impacto de números negativos muito grandes do NSE $[-\infty, 1]$ (Shin; Jung, 2022). O método Sobol estima a sensibilidade dos parâmetros decompondo a variância de saída do modelo, quantificada pela razão de sua contribuição para a variância de saída (Sobol et al., 1993; Shin et al., 2013). Em nesse estudo, usamos o TSI (Índice de Sensibilidade Total), pois ele fornece o efeito total de um parâmetro, incluindo todas as suas interações com outros parâmetros. Quanto maiores os valores do TSI, mais influente é o parâmetro; consequentemente, parâmetros com $TSI \approx 0$ podem ser considerados não influentes. Este trabalho usa o esquema de Saltelli (Saltelli, 2002) para calcular TSI com custo reduzido usando $n(k+2)$ em vez de $n(2k+2)$ com o método de amostragem aleatória de Monte Carlo para variáveis de entrada. Onde n é o tamanho inicial da amostra, foi adotado n igual a 1.000. Além disso, k denota o número de parâmetros no modelo hidrológico (quatro parâmetros para o GR4J). Portanto, o número total de amostras para análise de sensibilidade foi de 6.000 para cada bacia hidrográfica, resultando em 4.284.000 simulações para todas as 714 bacias hidrográficas e 29.988.000 simulações considerando todos os conjuntos de dados de precipitação.

3.4 RESULTADOS

3.4.1 Precisão dos produtos de precipitação em relação à precipitação de referência


As Fig. 13 e Fig. 14 resumem o desempenho dos diferentes produtos de precipitação. Os produtos de precipitação mostram valores medianos de r acima de 0,55 (Fig. 13, Fig. 14). CHIRPS, MERRA-2, ERA5 e IMERG apresentaram os maiores valores medianos de r ($r > 0,60$). ERA5 e MERRA-2 mostraram uma tendência a subestimar a precipitação com um valor mediano de P_{bias} de -2,5 e -4,7%, respectivamente. CHIRPS mostrou estimativas de precipitação imparciais ($P_{bias} = 0,1\%$), enquanto GLDAS, IMERG, PERSIANN-CDR e TRMM tendem a superestimar a precipitação. Os valores medianos de RMSE variaram de 5,88 mm/dia (MERRA-2) a 7,91 mm/dia (TRMM) e maiores nas bacias hidrográficas do Sul e menores nas bacias hidrográficas do Norte.

Figura 13 – Distribuição espacial das pontuações de desempenho para os sete diferentes produtos de precipitação (CHIRPS, ERA5, GLDAS, IMERG, MERRA-2, PERSIANN-CDR e TRMM) quando comparados com medições de precipitação médias baseadas na bacia hidrográfica



Fonte: O Autor (2024).


Figura 14 – Boxplots de métricas de desempenho (r , $pbias$, RMSE) para os produtos de precipitação (CHIRPS, ERA5, GLDAS, IMERG, MERRA-2, PERSIANN-CDR e TRMM) para todas as bacias hidrográficas



Fonte: O Autor (2024).

Todas as regiões hidrográficas geralmente apresentaram valores de r acima de 0,5 para todos os produtos de precipitação, com os melhores valores de r registrados para as regiões hidrográficas de São Francisco, Tocantins-Araguaia e Parnaíba (Fig. 15). Os produtos tenderam a superestimar a precipitação, exceto no Amazonas e nas regiões hidrográficas mais secas como Atlântico Oriental e Atlântico NE Oriental. (Fig. 15). Além disso, há maior recorrência dessa subestimação para o ERA5 em outras bacias. Como esperado, os maiores valores de RMSE foram registrados nas regiões com maior pluviosidade, como Amazônia e Atlântico Sul, e regiões hidrográficas do Uruguai com valores de RMSE acima de 6 mm/dia. As regiões hidrográficas com índice de aridez entre 1,24 e 2, principalmente em zonas tropicais com invernos secos (Aw) (Fig. 11 e Tabela 5), apresentaram melhor desempenho em termos do coeficiente r . Em contraste, as bacias hidrográficas mais secas e chuvosas do Brasil (regiões hidrográficas do Atlântico Nordeste Oriental e Atlântico Sul) tiveram o pior desempenho.

Figura 15 – Valores medianos das métricas de desempenho (r , pbias, RMSE) para os produtos de precipitação por região hidrográfica, classificados do mais chuvoso (superior) ao mais seco (inferior) de acordo com o índice de aridez




Fonte: O Autor (2024).

3.4.2 Avaliação hidrológica nas bacias brasileiras

3.4.2.1 Análise da simulação hidrológica baseada na calibração da Abordagem I

Na abordagem I, os modelos hidrológicos foram calibrados apenas com precipitação de referência e avaliados (nas fases de calibração e validação) com todos os produtos de precipitação. O desempenho dos produtos de precipitação e precipitação baseados em pluviômetros na simulação do fluxo diário do rio durante os períodos de calibração (janeiro de 2001 a dezembro de 2005) e validação (janeiro de 2006 a agosto de 2010) usando o modelo hidrológico GR4J é ilustrado nas Figs. 15 e D1 (Apêndice D). Como esperado, os modelos baseados em precipitação de referência apresentaram o melhor desempenho na simulação de vazões fluviais tanto para o período de calibração quanto para o período de validação. O CHIRPS apresentou um dos melhores desempenhos (em comparação com o resto dos produtos de precipitação da reanálise) na simulação de descargas fluviais (Fig. 15). Os resultados da calibração e validação indicam que o modelo GR4J pode capturar as características climáticas dos hidrogramas observados nas diferentes regiões hidrológicas do Brasil. Para a maioria das bacias hidrográficas (83,05%), o modelo GR4J apresenta valores de KGE superiores a 0,5 tanto para as fases de calibração quanto para validação das bacias hidrográficas simuladas com a precipitação de referência.

Figura 16 – Funções de distribuição cumulativa (CDF) do KGE para a precipitação com base em pluviômetros e os sete produtos de precipitação diferentes na simulação da vazão diária dos rios nas bacias brasileiras nas fases de calibração e validação



Fonte: O Autor (2024).

Os valores medianos das métricas estatísticas calculadas entre os hidrogramas observados e simulados utilizando os diferentes produtos de precipitação para todas as 714 bacias hidrográficas são mostrados na Tabela 7. Em comparação com as simulações baseadas em chuvas terrestres, as simulações com produtos de precipitação exibiram uma diminuição no desempenho durante os períodos de validação e calibração (Tabela 7). As diferenças mais notáveis no desempenho do modelo entre as simulações de chuvas terrestres e produtos de precipitação ocorreram nas regiões Nordeste e Sul do Brasil (Apêndice D, Fig. D1), resultados semelhantes foram obtidos nas mesmas regiões para a análise de precipitação.

Tabela 7 – Mediana e desvio padrão (valor mostrado entre parênteses) das métricas estatísticas para simulação de descarga para todas as 714 bacias hidrográficas selecionadas usando a abordagem de calibração I

Precipitation product	Calibration			Validation		
	r [0–1]	pbias (%) [-∞–∞]	KGE [-∞–1]	r [0–1]	pbias (%) [-∞–∞]	KGE [-∞–1]
Ground-based rainfall	0.88 (0.13)	0.60 (8.47)	0.83 (0.16)	0.87 (0.12)	1.80 (22.58)	0.75 (0.24)
CHIRPS	0.82 (0.15)	3.80 (15.26)	0.74 (0.20)	0.81 (0.15)	5.85 (23.59)	0.68 (0.28)
ERA5	0.74 (0.16)	-9.35 (29.36)	0.54 (0.27)	0.74 (0.15)	-3.90 (32.00)	0.55 (0.31)
GLDAS	0.74 (0.16)	11.90 (34.02)	0.60 (0.34)	0.71 (0.17)	15.95 (37.91)	0.52 (0.38)
IMERG	0.78 (0.15)	16.40 (26.99)	0.62 (0.34)	0.77 (0.15)	19.35 (31.98)	0.54 (0.45)
MERRA-2	0.82 (0.15)	-9.25 (18.09)	0.65 (0.21)	0.78 (0.15)	-19.35 (36.90)	0.50 (0.32)
PERSIANN-CDR	0.74 (0.16)	17.55 (33.83)	0.56 (0.34)	0.72 (0.16)	20.95 (37.08)	0.51 (0.56)
TRMM	0.77 (0.16)	18.80 (25.60)	0.58 (0.32)	0.76 (0.15)	24.55 (32.07)	0.50 (0.41)

Fonte: O Autor (2024).

3.4.2.2 Análise da simulação hidrológica baseada na calibração da Abordagem II

A Tabela 8 mostra o desempenho do modelo hidrológico calibrando os modelos individuais com um determinado produto de precipitação. Os resultados mostraram que, em comparação com a abordagem I de calibração, o desempenho hidrológico de todos os produtos melhorou (Tabela 8). A mediana r para o produto CHIRPS apresentou o maior valor tanto para o período de calibração (0,84) quanto para o período de validação (0,83), seguido pelos produtos IMERG e TRMM, que apresentaram valor de r de 0,81 para a fase de calibração e 0,80 para validação (Tabela 8).

Tabela 8 – Mediana e desvio padrão (valores mostrados entre parênteses) de métricas estatísticas para simulação de descarga para todas as 714 bacias hidrográficas selecionadas usando a abordagem de calibração II

Precipitation product	Calibration			Validation		
	r [0–1]	pbias (%) [$-\infty$ – ∞]	KGE [$-\infty$ –1]	r [0–1]	pbias (%) [$-\infty$ – ∞]	KGE [$-\infty$ –1]
CHIRPS	0.84 (0.14)	1.35 (8.39)	0.77 (0.18)	0.83 (0.14)	3.25 (25.58)	0.71 (0.37)
ERA5	0.76 (0.15)	0.70 (8.40)	0.66 (0.19)	0.75 (0.15)	4.65 (32.15)	0.60 (0.40)
GLDAS	0.76 (0.15)	0.30 (9.57)	0.68 (0.19)	0.73 (0.16)	4.95 (27.14)	0.61 (0.28)
IMERG	0.81 (0.14)	0.45 (8.93)	0.75 (0.18)	0.80 (0.14)	4.30 (23.36)	0.66 (0.30)
MERRA-2	0.84 (0.14)	1.10 (9.22)	0.76 (0.18)	0.79 (0.15)	-9.40 (31.47)	0.59 (0.30)
PERSIANN-CDR	0.77 (0.15)	1.10 (8.92)	0.68 (0.19)	0.73 (0.16)	4.80 (26.79)	0.61 (0.47)
TRMM	0.81 (0.14)	0.30 (8.46)	0.74 (0.18)	0.80 (0.14)	6.30 (26.81)	0.65 (0.34)


Fonte: O Autor (2024).

O desvio padrão dos valores de pbias aumentou no período de validação para todos os produtos, e os produtos satélites geralmente superestimaram o fluxo com valores medianos superiores a 0. Na fase de calibração, os melhores valores medianos de pbias foram fornecidos pelo ERA5 (0,7%) e TRMM (0,3%), enquanto na fase de validação os melhores valores foram

CHIRPS (3,25%) e IMERG (4,3%). Os valores medianos de KGE apresentam melhores resultados para CHIRPS, IMERG e TRMM, nesta ordem, com valores medianos de KGE acima de 0,64 para ambas as fases de calibração e validação.

Todos os produtos apresentaram valores de pbias de vazão média diária do rio próximos a zero na calibração e uma tendência de superestimação para o período de validação, com exceção do MERRA-2 e da região nordeste, especialmente para a bacia do rio São Francisco (Fig. 16). As métricas r e KGE apresentaram os piores desempenhos para algumas das bacias hidrográficas localizadas nas regiões Sul e Nordeste. Os valores de r para a vazão média diária do rio mostram bom desempenho para a maioria das bacias hidrográficas brasileiras, com valores de $r > 0,6$ para 85,6% das bacias hidrográficas para todos os produtos de precipitação usando a abordagem II (78,9% das bacias hidrográficas apresentaram $r > 0,6$ usando a abordagem I na fase de calibração). Em relação ao KGE, todos os produtos tiveram bom desempenho para a maioria das bacias hidrográficas na fase de calibração. Por exemplo, os valores médios de KGE são maiores que 0,5 para 78,0% (abordagem II) e 57,3% (abordagem I) das bacias hidrográficas simuladas com ERA5; 89,6% (abordagem II) e 69,0% (abordagem I) para IMERG; 91,3 e 87,1% para CHIRPS nas abordagens II e I, respectivamente. Os menores valores de KGE foram registrados em algumas das bacias hidrográficas do sul e nordeste do Brasil. Os resultados também mostraram que não há melhora consistente no desempenho do modelo hidrológico dos diferentes produtos de precipitação à medida que a área da bacia hidrográfica aumenta (Apêndice D, Fig. D3 B), ao contrário do desempenho da precipitação (Apêndice D, Fig. D3 A).


Figura 17 – Métricas de desempenho r , pbias e KGE para os sete diferentes produtos de precipitação na simulação da vazão diária dos rios das bacias brasileiras



Fonte: O Autor (2024).

O diagrama que relaciona o desempenho do KGE e do pbias das doze regiões hidrográficas do Brasil e da precipitação de referência e dos produtos de precipitação é apresentado na Figura 18. A região hidrográfica do Atlântico Nordeste Ocidental apresentou pbias abaixo de -6,55% e valor KGE acima de 0,72 para todos os produtos de precipitação. Em contraste, a região hidrográfica do Atlântico Leste superestimou os valores de vazão com valores de pbias acima de 1,95% para todos os produtos de precipitação. Os maiores valores de KGE ($>0,76$) foram registrados para as regiões hidrográficas da Amazônia, Tocantins-Araguaia e Paraguai para todos os produtos de precipitação. Estas regiões são afetadas principalmente pelas interações de várzea e consequente atenuação dos picos de cheia (Lininger; Latrubesse, 2016). Por outro lado, os menores valores de KGE ($<0,62$) foram registrados nas regiões hidrográficas mais áridas (Atlântico NE Oriental e Atlântico Leste) e Atlântico Sul.


Figura 18 – Diagrama das doze regiões hidrográficas em ordem decrescente por índice de aridez do Brasil para a precipitação de referência (GB) e os sete produtos para a fase de calibração. O tamanho de cada círculo indica o valor KGE mediano das bacias hidrográficas localizadas em uma dada região hidrográfica e um dado produto de precipitação. A cor de cada círculo indica o valor pbias mediano



Fonte: O Autor (2024).

A figura 19 mostra a diferença relativa entre os resultados e das avaliações diárias da vazão do rio e da precipitação para produtos de precipitação, de modo geral os produtos de precipitação de maior qualidade apresentaram uma melhor resposta hidrológica, como é o caso do CHIRPS e do IMERG; no entanto, em alguns casos como o do TRMM, essa relação não foi direta.


Figura 19 – A diferença relativa entre os resultados r das avaliações diárias da vazão do rio e da precipitação para produtos de precipitação (CHIRPS, ERA5, GLDAS, IMERG, PERSIANN-CDR, MERRA-2 e TRMM) na calibração e validação para abordagem II



Fonte: O Autor (2024).

Como esperado, os modelos que usam precipitação baseada em pluviômetros tiveram melhor desempenho no período de calibração do que os produtos de precipitação (Fig. 20 A e B) para aproximadamente 60% das bacias hidrográficas. No geral, as estimativas de escoamento usando os produtos de precipitação foram satisfatórias, com CHIRPS e MERRA-2 exibindo o melhor desempenho KGE para 36,3% e 13,4% das bacias hidrográficas, respectivamente, quando comparados com os produtos de precipitação baseados em satélite e reanálise (Fig. 20 B).

Figura 20 – Melhores valores de KGE para o período de calibração. A) Todos os produtos de precipitação, incluindo chuvas terrestres. B) Todos os produtos de precipitação, excluindo a precipitação baseada em medições terrestre




Fonte: O Autor (2024).

3.4.3 Sensibilidade dos parâmetros do modelo GR4J

Os resultados da sensibilidade dos parâmetros do modelo (Fig. 10) mostram que os parâmetros relacionados ao armazenamento de umidade do solo (X1) e à troca de água subterrânea (X2) exibem maior sensibilidade para a maioria dos conjuntos de dados, enquanto o parâmetro do hidrograma unitário (X4) é o menos sensível para a maioria dos conjuntos de dados de dados de precipitação ($TSI < 0,2$) (Fig. 21).


Figura 21 – Boxplot do *Total Sensitivity Indices* (TSI) do Sobol para os parâmetros GR4J para as 714 bacias analisadas



Fonte: O Autor (2024).

Os dados de precipitação de referência mostraram maior sensibilidade dos parâmetros do que outros produtos de precipitação; além disso, este resultado indica que a sensibilidade dos parâmetros do modelo pode mudar de acordo com o conjunto de dados de entrada. Além disso, os resultados mostram que a sensibilidade muda de acordo com o clima e a aridez da bacia hidrográfica; por exemplo, X1 é mais sensível em regiões de maior aridez, enquanto X2 é mais sensível em regiões com maior umidade (Fig. 22).

Figura 22 – Sensibilidade dos parâmetros do modelo hidrológico para cada conjunto de dados de entrada de precipitação. As bacias hidrográficas são classificadas por região hidrográfica de acordo com o índice de aridez (bacias mais secas à esquerda, bacias mais úmidas à direita)



Fonte: O Autor (2024).

3.5 DISCUSSÃO

3.5.1 Desempenho da estimativa de precipitação média na escada de bacia hidrográfica

No geral, os conjuntos de dados de precipitação mostraram uma tendência para sobrestimar, com exceção do ERA5 e MERRA-2 quando comparados com a precipitação de referência. Além disso, o desempenho dos produtos de precipitação muda dependendo da região hidrográfica, sendo que as bacias hidrográficas mais secas e úmidas do Brasil tiveram o pior desempenho. Esses achados reforçam o resultado de Andrade et al. (2022), que sugere que o desempenho dos produtos de satélite e de reanálise depende das características de cada sistema climático e pluviométrico que ocorre em uma determinada região. Jiang e Bauer-Gottwein (2019) indicaram que os produtos de precipitação baseados em satélite na China continental tendem a subestimar consistentemente nas zonas tropicais e, inversamente, a sobrestimar nas zonas mais áridas. A precipitação para as bacias hidrográficas localizadas próximas à costa do

Nordeste e Sudeste do Brasil tem maior tendência a subestimar a precipitação; isso pode ser explicado em parte pela presença de precipitação de chuva quente, que é mais difícil de medir por sensores infravermelhos de satélite (Gadelha et al., 2019; Nascimento, 2021; Andrade et al., 2022). Os topos das nuvens têm pouco desenvolvimento vertical e baixo teor de gelo e seriam demasiado quentes para que os limiares infravermelhos fossem detectados por estes sensores (Mitra et al., 2018; Derin et al., 2022). Os resultados confirmam que uma melhoria consistente no desempenho dos produtos de precipitação é observada à medida que a área da bacia hidrográfica aumenta (Fig. D3 A, Apêndice D); o estudo de Duan et al. (2016) indica que as métricas de avaliação melhoram à medida que a escala espacial aumenta da grade para escala de bacia. Esses resultados são consistentes com os resultados de Zhao et al. (2020) e Guo et al. (2023), que mostraram que o desempenho dos conjuntos de dados de precipitação melhora à medida que a escala espacial se torna maior.

3.5.2 Desempenho da modelagem hidrológica

Avaliamos os diferentes produtos de precipitação quando os modelos hidrológicos foram calibrados com base na precipitação de referência (Abordagem I). Os modelos hidrológicos apresentaram queda no desempenho quando avaliados com produtos de precipitação de reanálise para os períodos de calibração e validação (Tabela 8). Isto pode ser explicado pelos erros observados em alguns dos produtos de precipitação. Outra razão para esse comportamento é que os parâmetros calibrados pelo produto de precipitação baseado em pluviômetros não são ótimos para os produtos de precipitação (Su et al., 2021). As simulações hidrológicas com recalibração para cada produto de precipitação (Abordagem II) melhoraram a simulação das vazões fluviais. Esses resultados são consistentes com vários estudos (Zeng et al., 2018; Su et al., 2021; Khatakho et al., 2021) que concluíram que a eficiência da simulação hidrológica é aumentada pela recalibração específica de entrada. Isto pode ser explicado pela capacidade do modelo GR4J de amortecer erros e distorções nas entradas de precipitação através de parametrização específica dos produtos de precipitação, como mostrado na Figura D4 (Apêndice D), muitas vezes permitindo uma previsão de fluxo razoável mesmo com erros de entrada substanciais (Stephens et al., 2022). No entanto, os parâmetros do modelo calibrados com base nas entradas de precipitação tendenciosas, como produtos de precipitação baseados em satélite ou reanálises, podem não ser suficientes para caracterizar a simulação hidrológica na bacia, e os parâmetros de calibração podem ter intervalos inadequados (Su et al., 2019; Su et al., 2021). Além disso, o modelo GR4J está sujeito à equifinalidade, e mudanças sistemáticas

nos parâmetros baseadas em processos físicos não melhoram necessariamente o desempenho (Stephens et al., 2019). Utilizando uma função objetivo único, o desempenho do modelo apresentou valores de KGE superiores a 0,5 tanto para os períodos de calibração como de validação para 83,05% das bacias hidrográficas quando se utilizou precipitação de referência. O uso de técnicas de multioptimização e multiobjetivo aplicadas por Adeyeri et al. (2020) para calibração de modelos é algo a explorar em trabalhos futuros. Estes autores defendem que os fenômenos de equifinalidade, colocados por Beven (2002) como uma gama de modelos potencialmente aceitáveis, podem ser reduzidos melhorando a estimação dos valores dos parâmetros.

Os modelos hidrológicos conduzidos por CHIRPS, MERRA-2 e IMERG apresentaram métricas de desempenho ótimas na maioria das bacias hidrográficas ($KGE > 0,81$) durante a calibração, exceto nas regiões semiáridas. Uma explicação para o baixo desempenho da região semiárida pode ser um grande número de reservatórios na região nordeste do Brasil, o que não é considerado pelo modelo hidrológico utilizado neste estudo, além do baixo desempenho dos produtos de precipitação nesta região (Almagro et al., 2021b). Além disso, a maior proporção de vazões baixas e sua intermitência em comparação com bacias úmidas podem tornar a calibração do modelo hidrológico mais desafiadora (Messenger et al., 2021). O estudo de Jiang e Bauer-Gottwein (2019) também encontrou desempenho inferior em regiões mais áridas na China usando TRMM e IMERG.

Os modelos conduzidos pelo IMERG mostraram um desempenho hidrológico ligeiramente melhor do que aqueles conduzidos pelo TRMM; isso está alinhado com as descobertas de pesquisas anteriores (Jiang; Bauer-Gottwein, 2019; Zhao et al., 2020). Além disso, esse estudo mostrou que os produtos de precipitação de maior qualidade produziram uma melhor resposta hidrológica, que é o caso do CHIRPS, MERRA-2 e IMERG; no entanto, no caso do TRMM, essa relação não foi direta; uma explicação plausível para isso é que os erros nos produtos de precipitação são melhor compensados por meio de modelagem hidrológica em regiões úmidas (Fig. 19).

Isso é mais evidente para o TRMM porque este produto exibiu um dos piores desempenhos de precipitação em regiões úmidas (Fig. 13), enquanto os resultados de sua simulação hidrológica foram melhorados (Fig. 17). Além disso, outros estudos indicam que a qualidade dos produtos de precipitação e a resposta hidrológica podem não estar diretamente ligadas (Qi et al., 2016; Jiang; Bauer-Gottwein, 2019; Camici et al., 2020). Além disso, nenhuma melhoria consistente foi encontrada no desempenho dos modelos hidrológicos

impulsionados pelos produtos de precipitação à medida que a área de bacia aumenta, ao contrário do desempenho da precipitação, também verificado em outros estudos (Almagro et al., 2021b; Jiang; Bauer-Gottwein, 2019).

O fraco desempenho do modelo mostrado pelo KGE na região hidrográfica do Atlântico Sul pode ser devido à ausência de uma sazonalidade de precipitação bem definida (Fig. 11) (Siqueira et al., 2018; Almagro et al., 2021b). Além disso, em algumas regiões, os produtos de precipitação podem ter um desempenho melhor do que o produto baseado em medidas em superfície, o que pode ser útil, uma vez que a densidade das estações pluviométricas é relativamente escassa no Brasil, especialmente nas regiões da Amazônia e do Pantanal e em algumas áreas do Nordeste brasileiro (Gadelha et al., 2019). Devido à disponibilidade limitada da estação de monitoramento, Tarek et al. (2020) descobriram que as simulações hidrológicas baseadas em ERA5 superaram as simulações baseadas em precipitação observadas nas bacias montanhosas dos EUA e do Canadá. Isto destaca a reanálise e os dados de satélite como alternativas para observações em regiões com dados escassos.

3.5.3 Análise de sensibilidade

Os resultados mostraram que a sensibilidade dos parâmetros muda de acordo com o conjunto de dados de entrada, clima e aridez da bacia hidrográfica. O parâmetro X2 mostra maior sensibilidade para a maioria dos conjuntos de dados, resultados semelhantes foram encontrados no estudo de Wanzala et al. (2022) em 19 bacias hidrográficas propensas a inundações no Quênia, África Oriental. A sensibilidade depende da duração do período de dados, intervalos de parâmetros, características físicas das bacias hidrográficas, estruturas do modelo e condições climáticas, indicando que se deve ter cuidado ao fazer generalizações ou aplicá-las a novas situações (Shin et al., 2013; Arheimer et al., 2020). O estudo de Wang et al. (2023) com vinte e oito produtos pluviométricos de múltiplas fontes para uma bacia hidrográfica no sul dos Estados Unidos demonstra que um modelo hidrológico concentrado pode se adaptar a algumas entradas de precipitação imprecisas até um limite específico. Além disso, algumas das bacias hidrográficas desse estudo podem ser afetadas por chuvas ocasionais de alta intensidade que podem criar escoamento mesmo se o solo estiver seco (Santos et al., 2022).

Nas bacias hidrográficas localizadas em regiões de maior aridez, o parâmetro armazenamento de umidade do solo (X1) é mais sensível que os demais parâmetros. As regiões hidrográficas com maior umidade são mais sensíveis ao parâmetro X2. Em climas úmidos, uma

fração mais significativa da precipitação recarrega as águas subterrâneas, enquanto esta fração de recarga diminui em climas mais secos (Berghuijs et al., 2022); isto explica a menor sensibilidade do parâmetro X2 em comparação com o parâmetro X1 em bacias hidrográficas com maior aridez. As bacias mais áridas têm uma contribuição mínima ou nenhuma contribuição do fluxo de base, a maior parte da descarga do rio é gerada a partir do escoamento superficial direto, que é amplamente influenciado pela capacidade de infiltração do solo (Cantoni et al., 2022), o que pode explicar a sensibilidade do parâmetro X1.

3.6 CONCLUSÃO

No presente estudo, foi avaliado a precisão da precipitação, o desempenho do modelo hidrológico e a sensibilidade dos parâmetros relacionados a sete conjuntos de dados de precipitação com base em produtos de satélite e reanálise em 714 bacias hidrográficas tropicais e subtropicais contrastantes localizadas no Brasil. O ERA5 e o MERRA-2 são os únicos produtos que produzem estimativas de precipitação subestimadas para a maioria das bacias hidrográficas. As descobertas destacam discrepâncias no desempenho do modelo hidrológico entre os diferentes conjuntos de dados de precipitação em diferentes bacias hidrográficas em relação às regiões climáticas e à aridez. Os produtos de precipitação CHIRPS, IMERG e MERRA-2 mostraram a melhor precisão em termos de estimativa de precipitação e desempenho de simulação hidrológica; além disso, os erros nos produtos de precipitação baseados em satélite e reanálise são melhores compensados por meio de modelagem hidrológica em regiões úmidas. O estudo também fornece algumas descobertas sobre a análise de sensibilidade em bacias hidrográficas tropicais e subtropicais, onde a sensibilidade dos parâmetros do modelo varia de acordo com a entrada de precipitação, clima e aridez da bacia hidrográfica; o coeficiente de troca de água subterrânea (X2) foi altamente sensível na maioria das bacias hidrográficas, exceto nas mais secas, que foram mais responsivas ao parâmetro ligado à umidade do solo (X1).

A modelagem de chuva-vazão desempenha um papel importante na hidrologia e na gestão dos recursos hídricos, especialmente em regiões com falta de dados hidrometeorológicos. As descobertas desse estudo ajudam a melhorar a compreensão da resposta da bacia hidrográfica em regiões tropicais e subtropicais e a confiabilidade dos produtos de precipitação para simulação de vazão. Foi demonstrado a utilidade dos conjuntos de dados de precipitação como alternativas potenciais para aplicações hidrológicas em bacias hidrográficas tropicais e subtropicais. Especialmente em regiões com uma densidade

relativamente escassa de estações de pluviométricas, os produtos de precipitação baseados em satélite e reanálise podem auxiliar estudos meteorológicos, avaliação de alterações climáticas e gestão de recursos hídricos e desastres. No entanto, a incerteza associada a um determinado conjunto de dados de precipitação precisa de ser tida em conta, considerando que a precipitação é um dos principais fatores que influenciam a simulação de precipitação-escoamento.

Mais esforços são necessários para explorar melhor o impacto das características da bacia hidrográfica no desempenho dos produtos de precipitação na modelagem hidrológica. A limitação do período de dados de vazão não compromete a análise e as conclusões gerais deste estudo. No entanto, recomenda-se que estudos futuros, quando possível, usem séries temporais mais longas para reforçar a robustez do estudo. Modelos baseados em dados para simulação de vazão podem ser usados para avaliar melhor a influência humana, como a presença de represas e reservatórios na bacia. Além disso, o trabalho futuro pode se concentrar na avaliação do desempenho do fluxo sub-diário e eventos de inundação usando conjuntos de dados de precipitação baseados em produtos de satélite e reanálise.

4 SIMULAÇÕES DE VAZÃO NAS BACIAS TROPICAIS E SUBTROPICAIS COM MODELOS REGIONALIZADOS DE REDES NEURAI DE LONG SHORT-TERM MEMORY (LSTM) EM REGIMES HIDROGRÁFICOS CONTRASTANTES

Resumo

Este capítulo investiga a capacidade das redes neurais de *Long short-term memory* (LSTM) de realizar simulação de vazão em bacias secas e úmidas em regiões tropicais e subtropicais. Diferentes abordagens para construção dos modelos em LSTM são testadas em 176 bacias hidrográficas no Brasil em séries longas de pelo menos 30 anos usando 16 atributos da bacia hidrográfica como recursos de entrada estáticos. O objetivo desse estudo é explorar informações hidrológicas da bacia hidrográfica ao usar modelos de escoamento baseados em LSTM. As principais questões que este estudo pretende investigar são: (i) O padrão do desempenho em relação a variação do “lookback” dos modelos LSTM depende da região hidroclimatológica das bacias? (ii) Qual é a eficácia dos modelos baseados em LSTM na simulação do escoamento em bacias hidrográficas tropicais e subtropicais em condições secas e úmidas? Foram treinados modelos de LSTM em bacias hidrográficas dentro de mesmo regime e uma abordagem composta que utiliza toda a amostra (utilizando dados de regimes heterogêneos, secos e úmidos). Os resultados das LSTMs são comparados usando o modelo conceitual tradicional GR4J. Os achados do estudo indicam que o desempenho do LSTM tem maior sensibilidade ao comprimento da sequência de entrada (*lookbacks*) no regime úmido, e uma explicação seria que o processo hidrológico dominante nesse regime tem uma influência clara de longo prazo; assim as sequências de entrada longas são indicadas nessa situação. Este nível de sensibilidade não é observado nas bacias secas. Além disso, a diversificação da amostra com bacias em regimes hidrográficos contrastantes (seco e úmido), prejudicou a performance das bacias secas. No geral, as redes LSTM têm o potencial de auxiliar a regionalização de vazão utilizando características das bacias hidrográficas, cerca de 87% e 50% das bacias úmidas e secas, respectivamente, apresentaram valores de $KGE > 0,60$ no modelo regional de LSTM na fase de teste. As descobertas desse estudo destacam os pontos fortes e as limitações dos modelos LSTM em regiões hidroclimáticas contrastantes em bacias tropicais e subtropicais, o que poderia ser útil para decisões em escala local e regional usando integração autônoma ou potencial de modelos LSTM baseados em dados.

4.1 INTRODUÇÃO

Previsões diárias e mensais confiáveis de vazão são valiosas para o gerenciamento e alocação adequadas de recursos hídricos, bem como melhoram a operação de reservatórios (Delaney et al., 2020). A longo prazo, esses modelos hidrológicos preditivos podem trazer enormes benefícios ao meio ambiente e à sociedade, uma vez que os gestores de água e inundações necessitam de informações precisas de previsão de vazão com um tempo de antecedência útil para tomar decisões ideais de gerenciamento de água (Hapuarachchi et al., 2022). Deste modo, revelar a relação chuva-vazão controlada pelo regime de chuvas e propriedades geomorfológicas das bacias tem sido o principal tema dos estudos hidrológicos ao longo de muitos anos (Okkan et al., 2021). No entanto, o mecanismo de transformação da chuva em vazão é um processo bastante complexo e que envolve inúmeras variáveis que apresentam comportamentos não lineares devido a distribuição heterogênea dos componentes hidrológicos na bacia, além das variações espaço-temporais desses componentes (Song et al., 2012).

O modelo hidrológico é uma descrição matemática da compreensão e generalização do processo hidrológico que simula a evolução do armazenamento de água e fluxos de água com base na equação do balanço hídrico (Horton et al., 2022). Existe uma ampla gama de técnicas de modelagem hidrológica, desde séries temporais conceituais, físicas, estatísticas e estocásticas até modelos modernos de inteligência artificial (IA) híbridos que podem ser usados para previsão de vazão (Hapuarachchi et al., 2022). De modo geral, os modelos hidrológicos podem ser divididos em três tipos: modelos de base física, modelos conceituais e modelos empíricos ou orientados a dados (Jajarmizadeh et al., 2012; Noori; Kalin, 2016). Os modelos de base física utilizam informações de entrada distribuídas espacialmente, além de serem mais complexos, exigindo ainda um esforço computacional intensivo para parametrização do modelo (Jajarmizadeh et al., 2012; Noori; Kalin, 2016). Já os modelos conceituais de chuva-vazão são modelos hidrológicos que simulam o fluxo com base em séries temporais de entrada de chuva diária e evapotranspiração potencial (PET) em uma área de bacia (Horton et al., 2022). Na modelagem conceitual, toda a bacia costuma ser considerada homogênea. O modelo conceitual pode ser uma explicação mais macroscópica do processo hidrológico, em que é feita uma abstração sobre os vários processos microscópicos subjacentes à observação (Horton et al., 2022).

Ao contrário dos modelos conceituais tradicionais de chuva-escoamento, onde as regras hidrológicas estão embutidas no modelo, os modelos baseados em dados englobam várias técnicas estatísticas (Jajarmizadeh et al., 2012; Humphrey et al., 2016; Noori; Kalin, 2016),

desde modelos de regressão até algoritmos mais abrangentes de *machine learning* (ML) e *deep learning* como a rede neural *Long short-term memory* (LSTM) (Hochreiter e Schmidhuber, 1997), esses modelos podem ser uma opção mais prática para simulação da vazão com menos parâmetros e dados (Ren et al., 2018; Okkan et al., 2021, Hashemi et al., 2023). O LSTM utiliza uma “sequência” passada das variáveis independentes para prever o escoamento, a duração desta sequência passada é denominada “*lookback*” (Kratzert et al., 2018; Hashemi et al., 2022). Esses modelos promissores de escoamento contínuo baseados em (LSTM) foram introduzidos pela primeira vez por Kratzert et al. (2018) em 2018. Desde então, sua aplicação foi bem-sucedida em inúmeros estudos em diversas bacias hidrográficas no mundo (Fan et al., 2020; Bai et al., 2021; Althoff et al., 2021; Khand; Senay, 2024).

Um recorrente problema na hidrologia é como usar um modelo, ou um conjunto de modelos, para fornecer simulações hidrológicas espacialmente contínuas em grandes áreas (por exemplo, regional, continental, global) (Kratzert et al., 2019). A regionalização depende do modelo e tem recebido grande atenção da comunidade hidrológica, especialmente para utilização de redes neurais de LSTM para regionalização, de modo que hoje existe uma grande variedade de abordagens. Por exemplo, Arsenault et al. (2023) investigaram a capacidade de rede neurais de LSTM de realizar previsão de vazão em bacias não avaliadas em 148 bacias hidrográficas no nordeste da América do Norte, comparando-as com métodos de regionalização dependentes de modelos hidrológicos de última geração, e seus achados indicam que a estrutura do modelo LSTM era mais adequada para converter os dados meteorológicos e descritores geofísicos em vazões do que os modelos hidrológicos. Em outro estudo, Hashemi et al. (2022) avaliam diferentes abordagens de utilização em um contexto regional e nacional em 361 bacias hidrográficas medidas com condições hidrológicas muito diversas de toda a França, em que seus resultados indicam que a sensibilidade do “*lookback*” varia de acordo com o regime hidrológico.

Assim, um interesse central deste trabalho é como se pode beneficiar do conhecimento do domínio e das práticas tradicionais em hidrologia e utilizar modelos LSTM para a simulação de escoamento em bacias hidrográficas tropicais e subtropicais, uma vez que ainda existe uma escassez de estudos que utilizam a LSTM de modo regionalizado em bacias tropicais. Por exemplo, Althoff et al. (2021) avaliaram um modelo regionalizado de LSTM em 411 bacias hidrográficas para o bioma do Cerrado brasileiro, enquanto Nogueira Filho et al. (2022) utilizaram a LSTM para regionalizar a vazão em região semiárida em 25 bacias localizadas no Estado do Ceará, Nordeste do Brasil. Até o momento, esse é o primeiro estudo que compara de

modo mais abrangente a regionalização das vazões em condições heterogêneas (bacias úmidas vs bacias secas) com uso de LSTM em regiões tropicais e subtropicais. O objetivo desse estudo é explorar informações hidrológicas da bacia hidrográfica ao usar modelos de escoamento baseados em LSTM em regimes heterogêneos (seco e úmido). As principais questões que este estudo pretende responder são: (i) O padrão do desempenho em relação a variação do “lookback” dos modelos LSTM depende da região hidroclimatológica das bacias? (ii) Qual é a eficácia dos modelos baseados em LSTM na simulação do escoamento em bacias hidrográficas tropicais e subtropicais em condições secas e úmidas?

4.2 DADOS

4.2.1 Dados hidrometeorológicos

Os dados utilizados neste estudo contêm séries temporais de variáveis hidrometeorológicas e atributos estáticos da bacia hidrográfica para um período comum de 1 de outubro de 1980 a 30 de setembro de 2010, totalizando 30 anos de dados. Os dados foram derivados de um conjunto maior do *Catchment Attributes for Brazil* (CABra) que contém atributos e informações hidrometeorológicas de 735 bacias hidrográficas no Brasil (Almagro et al., 2021a), em que, deste total foram selecionadas as bacias que possuíam mais de 99% dos dados de vazão para o período, totalizando um subconjunto de 515 bacias. Deste conjunto, foi selecionada uma amostra de 176 bacias hidrográficas.


4.2.2 Classificação da bacia hidrográfica

A classificação proposta nesse trabalho, se baseia no índice de aridez calculado a partir dos valores médios diários de evapotranspiração potencial (PET) e precipitação (P) (Arora, 2002). As bacias hidrográficas com valores de índice de aridez acima de 2 são classificadas como secas; já as bacias hidrográficas com índice de aridez menor que 1 são as bacias úmidas. Desse modo, baseado nessa classificação, 54 bacias são classificadas como secas e 122 bacias são úmidas, totalizando uma amostra de 176 bacias hidrográficas.

A localização das bacias hidrográficas dentro de cada regime é mostrada na Figura 23. Pode-se observar que os regimes são geograficamente plausíveis e compatíveis com as características geográficas da região. As bacias hidrográficas secas estão distribuídas em boa parte no bioma da Caatinga, na região semiárida do Brasil onde as estações secas são longas

com mais de 6 meses e taxas de precipitação abaixo de 800 mm/ano. Já as bacias úmidas estão localizadas principalmente no sul temperado e na região Amazônica do Brasil com estações secas mais curtas (menos de 3 meses) e com as maiores taxas de precipitação (valores acima de 1800 mm/ano) (Chagas et al., 2024).


Figura 23 – Área de estudo e localização das bacias hidrográficas. A) Mapa de localização contendo as saídas das 54 bacias hidrográficas secas (*Dry*) e 122 bacias úmidas (*Wet*). Para cada região, a precipitação média de longo prazo da área (azul) e o fluxo médio de todas as bacias hidrográficas dentro dela são representados: B) bacias secas (*Dry*) e C) bacias úmidas (*Wet*). As áreas sombreadas (cinza) representam a faixa de vazão diária para as regiões hidrográficas



Fonte: O Autor (2024).

Para cada regime, os valores de precipitação total, evapotranspiração potencial (PET), escoamento anual, e elevação média são apresentados na Figura 24. A região seca apresenta valores aproximados de precipitação de 876 mm/ano e PET de ~2160 mm/ano, observando um período seco ao longo do ano. No regime úmido as bacias apresentam altas taxas de precipitação ~1900 mm/ano e escoamento superficial de ~961 mm/ano, com a variação menor no escoamento superficial ao longo dos anos. As bacias hidrográficas variam em tamanho entre 21,9 e 641844,7 km², com uma dimensão média de 2794,5 km². A elevação média varia de 70 m à 1646 m. Já o escoamento anual varia de 14 a 2467 mm/ano, com um valor médio de 852.3 mm/ano; a precipitação total anual varia entre 595 e 2738 mm/ano, com um valor médio de 1.585 mm/ano, e a evapotranspiração potencial anual varia de 1544 a 2336 mm/ano.

Figura 24 – Características de cada bacia hidrográfica: a) precipitação (mm/ano), b) PET (mm/ano), c) Vazão em mm/ano e d) média da elevação (m)



Fonte: O Autor (2024).

4.2.3 Atributos físicos e climáticos da bacia hidrográfica

Neste trabalho, utilizou-se quatro atributos físicos: área, elevação, declividade e ordem do rio; quatro atributos climáticos: precipitação e evapotranspiração, temperatura máxima e mínima; dois hidrológicos: coeficiente de escoamento e valor médio de escoamento diário em mm; dois parâmetros de cobertura do solo: porcentagem de cobertura urbana e culturas de cobertura, e dois antropogênicos: número de reservatórios e índice de distúrbio hidrológico, conforme visualizado na Tabela 9. Essas informações foram extraídas do CABra (Almagro et al., 2021a).

Tabela 9 – Lista dos recursos dinâmicos e estáticos usados em diferentes modelos LSTM

Classe	Característica	Natureza	Etapa de tempo	Unidade
Clima	Precipitação	Dinâmico	Diário	(mm.d-1)
	PET	Dinâmico	Diário	(mm.d-1)
	Precipitação média	Estático	-	mm
	PET médio	Estático	-	mm
	Temperatura mínima do ar	Estático	-	°C
	Temperatura máxima do ar	Estático	-	°C
Hidrológica	Índice de Aridez	Estático	-	-
	Coefficiente de escoamento	Estático	-	-
	Escoamento médio	Estático	-	mm
	Índice de fluxo de base	Estático	-	-
Topográfica	Área	Estático	-	Km ²
	Elevação	Estático	-	m
	Declividade	Estático	-	%
Cobertura do solo	Ordem do rio	Estático	-	-
	Culturas de cobertura	Estático	-	%
Antropogênico	Cobertura urbana	Estático	-	%
	Índice de distúrbio hidrológico	Estático	-	-
	Número de reservatórios	Estático	-	-


Fonte: Almagro et al. (2021a)

4.3 METODOLOGIA

4.3.1 Long short-term memory (LSTM)

As redes LSTM pertencem à família das redes neurais recorrentes e foram desenvolvidas para resolver problemas relacionados aos gradientes de desaparecimento e explosão (Hochreiter, 1998). Essas redes se mostraram eficazes na modelagem de sistemas dependentes do tempo, especialmente quando existem "atrasos desconhecidos" na resposta de um sistema a uma entrada contínua. Isso é exemplificado na conversão da chuva em escoamento superficial em uma bacia hidrográfica. No contexto das LSTM, a captura de dependências temporais pode ser entendida como o compartilhamento de informações relevantes entre diferentes momentos de uma série temporal (Goodfellow et al., 2016). O procedimento para construção do modelo LSTM é mostrado na Figura 25.

Figura 25 – Estrutura da célula de memória LSTM: processamento de dados da última etapa de tempo da amostra acima através de uma célula LSTM



Fonte: Adaptado de Hashemi et al. (2022).

x_t é a entrada do intervalo de tempo t , h_t é o estado oculto, C_t representa o estado da célula e σ e $\tanh$ são as respectivas a funções sigmoide e tangente hiperbólico. W e b representam, respectivamente, o peso e o valor da polarização de cada porta.

O conceito central do LSTM é o estado da célula e a estrutura de “portas” de rede (Figura 3). Os estados da célula podem transmitir informações e superar os efeitos da memória de curto prazo. O LSTM possui três tipos de estruturas de portas: portas de entrada, de esquecimento e de saída, cada uma das quais com sua função única (Olah, 2015). A porta de entrada é usada para atualizar o estado da célula. As informações do estado anteriormente oculto e da entrada atual são passadas para a função sigmoide, que ajusta o valor entre 0 e 1 para determinar as informações a serem atualizadas.

A próxima etapa é calcular o estado da célula, o estado da célula da camada anterior é multiplicado pelo vetor de esquecimento. Se for multiplicado por um valor próximo de 1, significa que a informação precisa ser retida no novo estado da célula. Já o estado oculto anterior e a entrada atual são passados para a função sigmoide, e o estado da célula recém-obtido é passado para a função de ativação tanh e finalmente, a saída da função de ativação tanh é multiplicada pelo resultado da função de ativação sigmoide para determinar a informação que o estado oculto deve transportar (Zha et al., 2022). O estado oculto é usado como saída da célula atual, e o novo estado da célula e estado oculto são passados para a próxima etapa de tempo (Zha et al., 2022). Para maior compreensão sobre a estrutura da LSTM verificar Olah (2015).

4.3.2 Configurações dos inputs e abordagens para modelagem da LSTM

Para obter os conjuntos de dados de treino, validação e teste, os dados de cada bacia hidrográfica individual são divididos em três conjuntos da seguinte forma: o período de teste é de 18 anos (Out–1980 a Set–1998); o período de validação é de 6 anos (Out–1998 a Set–2006) e o período mais recente contendo 6 anos de registros de descarga completa é definido como o período de teste (Out–2004 a Set–2010). O objetivo do período de treino é alimentar a LSTM para identificar os padrões dos dados, enquanto o período de validação serve para monitorar seu desempenho e auxilia o ajuste dos hiperparâmetros, evitando o sobreajuste (*overfitting*) do modelo; já o período de teste serve para avaliar o desempenho final do modelo. Os valores dos recursos variam amplamente, então é realizada uma padronização em termos de recursos. A padronização é realizada utilizando a média e o desvio padrão dos dados de treinamento, e consiste em um método amplamente utilizado (Kratzert et al., 2019; Hashemi et al., 2022).

Este estudo centra-se na capacidade de um único modelo regional de LSTM capturar comportamentos hidrológicos em diferentes bacias hidrográficas, em vez da tradicional calibração estação por estação de múltiplos modelos. Duas configurações de entrada são usadas para treinar diferentes modelos de LSTM utilizando 16 atributos estáticos e dois atributos dinâmicos (Tabela 1), em que foi utilizada a *mean squared error* (MSE) como função de perda em ambos os cenários:

- (i) Modelo regional: um único modelo hidrológico LSTM é treinado usando todas as bacias hidrográficas de uma região com o mesmo regime.
- (ii) Modelo composto: um único modelo hidrológico LSTM é treinado usando todas as bacias hidrográficas de ambos os regimes (seco e úmido).

4.3.3 Ajuste de hiperparâmetros e taxa de aprendizagem

Ao abordar uma questão de pesquisa usando um modelo de aprendizagem profunda, é importante limitar (tanto quanto possível) quaisquer potenciais vieses de conclusão resultantes do uso de um modelo que não seja ajustado por hiperparâmetros. O LSTM possui, em particular, dois hiperparâmetros interconectados que precisam ser ajustados em conjunto: o *lookback* (duração da sequência de eventos passados das variáveis de entrada) e o tamanho da unidade oculta. Foram testadas 5 variações de *lookback* (15, 30, 60, 90 e 120 dias). Em todos esses casos, o tamanho do lote, *epoch*, o número de camadas LSTM e a taxa de aprendizado são constantes: 128, 100, 1 e 10^{-4} respectivamente.

O algoritmo Adam foi utilizado para otimização do modelo. Esse algoritmo é baseado em gradiente, pertence à família de algoritmos com taxas de aprendizagem adaptativas, e é considerado um algoritmo robusto no que diz respeito à escolha de seus hiperparâmetros, incluindo sua taxa básica de aprendizagem (Goodfellow et al., 2016; Kingma; Ba, 2017). Para controlar o sobreajustamento e para a modelagem de todas LSTMs, foi utilizada a biblioteca Keras (Chollet, 2018) escrita em Python 3.8 (Van Rossum; Drake, 2009). No caso do sobreajustamento, utiliza-se o algoritmo de parada antecipada do Keras.

4.3.4 Modelo de referência conceitual: GR4J

O modelo GR4J diário concentrado foi selecionado para realizar a comparação das abordagens do modelo LSTM. O GR4J foi escolhido por apresentar resultados satisfatórios para as bacias tropicais e subtropicais como indicado por (Andrade et al., 2024) e por ser utilizado em inúmeros estudos como *benchmark* de alta qualidade para comparar com a LSTM (Ayzel; Heistermann, 2021; Hashemi et al., 2022; Arsenault et al., 2023). O GR4J é capaz de contabilizar as trocas de águas subterrâneas, o que é uma característica que o distingue de outros modelos conceituais (Perrin et al., 2003; Hashemi et al., 2022). GR4J é um modelo parcimonioso que usa evapotranspiração diária (mm/dia) e precipitação total diária (mm/dia) como entradas e incorpora apenas quatro parâmetros livres. Esses parâmetros representam a capacidade máxima do reservatório de produção (X_1 , em mm), o coeficiente de troca de água subterrânea (X_2 , mm), a capacidade máxima para o dia seguinte do reservatório de roteamento (X_3 , em mm) e a base de tempo do hidrograma unitário (X_4 , dia).

O período de calibração para modelagem do GR4J compreende os dados de treinamento + validação utilizado na modelagem do LSTM (Tópico 4.3.2) e para sua avaliação o conjunto de dados de teste. Para o GR4J, recomenda-se que seja considerado um período de aquecimento para fornecer ao modelo um estado inicial, em vez de começar com um estado arbitrário (Perrin et al., 2003), assim em todas as simulações para cada bacia hidrográfica o primeiro ano foi definido com um período de aquecimento do modelo. A calibração do modelo GR4J e simulações de escoamento foram realizadas utilizando o pacote AirGR (Coron et al., 2017; Coron et al., 2018) na interface R (R Development Core Team, 2015). Os quatro parâmetros do modelo GR4J foram calibrados usando o algoritmo de otimização de Michel (Michel, 1991) e a eficiência Nash-Sutcliffe (NSE) (Nash; Sutcliffe, 1970) foi selecionado como função objetivo.

4.3.5 Critérios para avaliação de desempenho


Neste trabalho, utilizou-se a pontuação de eficiência Kling-Gupta (KGE) (Gupta et al., 2009) para avaliar o desempenho da previsão de escoamento superficial. O KGE (Eq.16) combina três propriedades diagnósticas fundamentais de um modelo hidrológico preditivo, variabilidade (α), viés (β) e correlação linear r . O KGE varia de $-\infty$ a 1, com uma pontuação perfeita de 1. Valores acima de 0,55 e 0,75 são considerados intermediários e bons, respectivamente (Brighenti et al., 2019).

4.4 RESULTADOS

4.4.1 Variação do desempenho do LSTM por região climática

A Figura 26 mostra três curvas representando as pontuações medianas do KGE para os conjuntos de dados de treinamento, validação e teste. Para ambos os modelos, as curvas tendem a apresentar um padrão consistente dentro das regiões, e tanto a inclinação como o *lookback* parecem depender da região.

Figura 26 – Variações de desempenho do LSTM em relação ao comprimento das sequências de entrada (*lookback*) dentro de diferentes regimes para o modelo regional de LSTM: a) regime seco (*Dry*) e b) regime úmido (*Wet*). Em cada painel, as linhas correspondem às pontuações medianas do KGE da fase de treino, validação e teste respectivamente




Fonte: O Autor (2024).

O KGE mediano na região úmida aumenta primeiro em uma determinada inclinação ascendente e depois essa inclinação fica menos acentuada. Nas bacias úmidas, a inclinação é distintamente pronunciada em comparação com as bacias secas. A inclinação na região seca apresenta pouca variação e uma menor sensibilidade global em relação às variações de *lookback*. A faixa de variação no KGE mediano é de 0.43-0.45 e 0.72-0.80 para os modelos nas regiões seca e úmida, respectivamente.

A Figura 27 compara a função de distribuição cumulativa (CDF) do KGE para os LSTMs regionais e a nível nacional utilizando o *lookback* de 60 dias. O desempenho da regionalização na região úmida supera o da região seca, a mediana do KGE é de 0,79 para região úmida versus 0,45 para região seca na fase de teste. Cerca de 88% e 40% das bacias úmidas e secas, respectivamente, apresentaram valores de $KGE > 0,60$ no modelo regional de LSTM na fase de teste.


Figura 27 – Funções de distribuição acumulada (CDF) do KGE do modelo regional de LSTM para as bacias da região seca (Dry) e úmida (Wet) na fase de teste



Fonte: O Autor (2024).

Observou-se uma variabilidade espacial do KGE para a simulação da vazão (Figura 28). As bacias que se encontram na porção submédia e baixa da bacia do São Francisco (Nordeste do Brasil) apresentaram os piores valores na fase de teste. Enquanto, em torno de 74% das bacias na região úmida, localizadas em sua maioria na porção sul do Brasil e na região Amazônica, apresentam valores de $KGE > 0,70$ em todas as fases (teste, validação e teste).


Figura 28 – Distribuição espacial das pontuações de desempenho de KGE para o modelo regional de LSTM para as fases de treino, validação e teste



Fonte: O Autor (2024).

Pode ser visto na Figura 29 que a maioria dos atributos da bacia tem pouca ou nenhuma correlação linear com o valor de KGE do LSTM na fase de teste. No entanto, algumas características apresentam comportamento distinto dependendo do regime climático. Por exemplo, a quantidade de reservatórios apresenta maior correlação com o desempenho do KGE nas bacias secas quando comparado com as bacias úmidas. Além disso, observa-se uma inclinação negativa para o índice de aridez nas bacias secas e inclinação positiva para as bacias úmidas, o que indica que condições extremas dificultam a simulação da vazão. Nas bacias úmidas, as características relacionadas aos aspectos hidrológicos, como coeficiente de escoamento e valor médio de vazão anual, apresentaram as maiores correlações, com valores de -0,35 e -0,37, respectivamente. Nas bacias secas por sua vez, as características relacionadas ao clima, como temperatura, precipitação e PET, foram mais proeminentes. De modo geral, pode-se observar que a maioria dos descritores de bacia hidrográfica apresentam pouca correlação linear com o valor de KGE do LSTM na fase de teste.

Figura 29 – Dispersão entre KGE do modelo regional de LSTM da fase de teste e os vários descritores de bacia hidrográfica utilizados neste estudo (Tabela 9) para cada uma das 176 bacias estudadas: A) 54 bacias secas e B) 122 bacias úmidas. Os coeficientes de correlação r são exibidos em cada gráfico




Fonte: O Autor (2024).

4.4.2 Comparação de desempenho entre diferentes abordagens de treinamento da LSTM e o modelo GR4J


A Figura 30 compara as pontuações medianas do KGE do modelo GR4J com os modelos LSTM para os períodos de “treinamento + validação” e teste. É possível observar que o GR4J é geralmente mais robusto que o modelo de LSTM composto. Já olhando para a pontuação mediana do KGE nos diferentes regimes durante o período de teste, o LSTM regionalizado supera o GR4J ou têm a mesma pontuação em 43% das bacias hidrográficas (Figura 31). As pontuações medianas do KGE permanecem muito próximas, KGE=0,79 e KGE=0,78, respectivamente para o LSTM regional e LSTM composto para as bacias úmidas, no entanto para as bacias secas ocorre um decréscimo acentuado na pontuação do KGE. No geral, as bacias úmidas apresentam desempenhos semelhantes entre os modelos de LSTM e GR4J, enquanto a mediana de KGE da LSTM regional para a região seca (KGE=0,45) supera o modelo GR4J (KGE=0,41), embora a diferença de desempenho seja pequena. Além disso, a região seca foi a que apresentou as maiores diferenças positivas e negativas entre o modelo LSTM regional e o modelo GR4J (Figura 8), e as bacias úmidas apresentaram uma diferença menos acentuada entre o valor de KGE entre as fases de treino e teste.

Figura 30 – *Boxplots* das pontuações de desempenho de KGE obtidas para 174 bacias hidrográficas distribuídas na região seca e úmida: a) Modelo de LSTM regional, b) Modelo de LSTM composto e c) Modelo GR4J



Fonte: O Autor (2024).

Figura 31 – Distribuição espacial da diferença entre a fase de teste do modelo de LSTM regional e GR4J



Fonte: O Autor (2024).

4.5 DISCUSSÃO

4.5.1 O padrão retrospectivo (*lookback*) e a variabilidade espacial do desempenho das LSTMs

As bacias hidrográficas em regiões úmidas apresentam uma tendência mais acentuada de melhorar o desempenho com o aumento do *lookback*. Uma explicação para isso seria a dinâmica de longo prazo dos seus processos hidrológicos dominantes nessas bacias, como por exemplo a recarga e descarga dos aquíferos. As bacias hidrográficas úmidas ocorrem principalmente em áreas conhecidas por ter alta influência de grandes aquíferos, como os aquíferos Guarani no Sul e Sudeste do Brasil, e a bacia do rio Amazonas com os aquíferos Alter do Chão e Solimões (Diniz et al., 2014). O fluxo de base e tais aquíferos podem modificar significativamente a dinâmica temporal do fluxo superficial das bacias hidrográficas, como por exemplo, o fluxo pode depender de precipitações de períodos anteriores (Hashemi et al., 2022). Já nas bacias hidrográficas em regiões secas, não é observado um padrão contínuo no desempenho do KGE em diferentes *lookbacks*, e isso pode ser explicado pela dinâmica de curto e médio prazo que atuam nos processos hidrológicos na bacias secas, pois estas bacias estão localizadas majoritariamente no Nordeste do Brasil, região que ocorre um predomínio da presença de terrenos cristalinos (Diniz et al., 2014), o que favorece o baixo armazenamento de água subterrânea e baixa condutividade hidráulica. No estudo de Chagas et al. (2024), seus achados indicam que as propriedades geológicas são as características mais importantes da bacia hidrográfica para a variabilidade espacial do baixo fluxo.

Além disso, a variabilidade do desempenho da modelagem hidrológica entre as regiões climáticas brasileiras também foi observada na análise diária de vazão em outros estudos como Siqueira et al. (2018) e Andrade et al. (2024). Esses estudos, também, indicaram valores de KGE superiores na maioria das bacias hidrográficas úmidas em relação às bacias secas. Além disso, o baixo desempenho das bacias na porção submédica e baixa da bacia hidrográfica do São Francisco pode ser explicado pela regularização e operação dos reservatórios, além da exploração de águas subterrâneas nessas regiões (Lucas et al., 2021) que dificulta a interpretação do modelo LSTM, apesar da quantidade de reservatórios ser uma das características utilizadas na modelagem da LSTM. Uma das medidas para melhorar o desempenho nesse tipo de sistema, poderia ser adicionar informações sobre a operação desses reservatórios, por exemplo, no estudo de Tursun et al. (2024) os resultados fornecem evidências de que um modelo de LSTM proposto simula efetivamente os processos de geração de fluxo

em bacias hidrográficas reguladas pelo homem em regiões áridas. Além disso, de acordo com a Figura 7, observa-se que a maioria dos descritores de bacia hidrográfica apresentam pouca ou nenhuma correlação linear com o teste KGE do LSTM. No estudo de Arsenault et al. (2023), foi observado que a maioria dos descritores de bacia hidrográfica tem pouca ou nenhuma correlação linear com o teste NSE do LSTM e que não existe uma estrutura notável, o que parece indicar que o LSTM não favorece um tipo de bacia hidrográfica em detrimento de outro. No entanto, a estrutura da LSTM pode se beneficiar da ação conjunto dos descritores, o que pode não ficar evidente em uma análise de correção linear individual entre o desempenho da LSTM e as características da bacia.

4.5.2 Comparação entre as diferentes abordagens de regionalização da LSTM com um modelo hidrológico conceitual

Com os resultados, observa-se que o modelo regional fornece melhores valores de KGE quando comparado com o modelo composto. No modelo composto, as métricas de avaliação foram semelhantes ao modelo regional na região úmida e substancialmente menor na região seca, indicando que as bacias sofreram uma maior penalização. Inúmeros estudos relataram melhor desempenho de modelos treinados em múltiplas bacias (Kratzert et al., 2019; Althoff et al., 2021), no entanto, alguns estudos comparam o desempenho dos modelos por regiões e a nível nacional. Por exemplo, no estudo de Khand e Senay (2024), os autores investigaram o desempenho dos modelos locais treinados em bacia única, regionais treinados em múltiplas bacias (um modelo para uma região) e modelos compostos (um modelo para várias regiões) para prever a vazão diária em 18 bacias com limitação de água e 27 bacias úmidas. Em seus resultados, os autores também indicaram que um modelo regional apresentava melhor desempenho que os modelos treinados com múltiplas bacias em ambas as regiões.

Os resultados obtidos neste estudo mostram que em 176 bacias hidrográficas, o LSTM foi capaz de competir com a modelagem hidrológica conceitual em mais de 43% das bacias hidrográficas (Figura 9). Este estudo confirma as tendências recentes na literatura segundo as quais os LSTMs calibrados de modo regional são capazes de simular vazões com níveis de desempenho competindo com os métodos baseados em uma modelagem hidrológica conceitual (Althoff et al., 2021; Hashemi et al., 2022; Mai et al., 2022; Arsenault et al., 2023; Izadi et al., 2024). A estrutura LSTM muito flexível pode ser adaptada a várias regiões e treinar automaticamente os seus pesos em novos dados para representar diferentes processos físicos

(Arsenault et al., 2023). No entanto, os LSTMs também são limitados e desfavorecidos em alguns aspectos, como por exemplo na abordagem composta, quando foram utilizadas bacias hidrográficas de características heterogêneas, penalizando as bacias secas. Outra limitação é a necessidade de longas séries temporais de dados de observação para treinar adequadamente os modelos LSTM quando comparados com os modelos hidrológicos tradicionais (Arsenault et al., 2023). Por exemplo, séries temporais mais curtas podem não fornecer exemplos de treinamento suficientes para que os modelos LSTM aprendam os padrões necessários para as simulações hidrológicas adequadas (Ayzel; Heistermann, 2021; Gauch et al., 2021).

4.6 CONCLUSÃO

Neste estudo, foram utilizadas 176 bacias hidrográficas agrupadas em um contexto hidrológicamente heterogêneo em bacias tropicais e subtropicais no Brasil. O objetivo desse estudo é avaliar informações hidrológicas da bacia hidrográfica ao usar modelos de escoamento baseados em LSTM em regimes heterogêneos. Assim, este trabalho utiliza uma classificação de regime baseado no índice de aridez para identificar bacias hidrográficas com comportamentos semelhantes. Utilizamos duas abordagens de treinamento da LSTMs: (i) uma escala regional que utiliza apenas bacias de um grupo e (ii) uma escala composta que utiliza todas as 176 bacias hidrográficas. Os principais achados do trabalho são recapitulados nos parágrafos seguintes.

Nas bacias hidrográficas úmidas, existe um processo hidrológico dominante de longo prazo, pois foi encontrado um padrão entre o desempenho da LSTM regional com o aumento do *lookback*. Já nas bacias secas, isso não é observado, e uma explicação para isso deve estar relacionado às diferentes dinâmicas temporais subjacentes neste regime, dado que várias bacias hidrográficas nesta circunstância podem ser localmente afetadas pela presença de características geológicas cristalinas. Na simulação do LSTM, utilizando dados dos dois regimes ocorreu maior generalização do modelo para assimilar as características contrastantes entre as amostras, o que acabou penalizando mais as bacias secas. Os resultados indicam que o treinamento em nível regional teve um melhor desempenho geral e os modelos LSTMs calibrados de modo regional são capazes de prever vazões com níveis de desempenho competindo com os métodos baseados em uma modelagem hidrológica conceitual.

As descobertas desse estudo destacam os pontos fortes e as limitações dos modelos regionais de LSTM em regiões hidroclimáticas contrastantes em bacias tropicais e subtropicais, o que poderia ser útil para decisões em escala local e regional usando integração autônoma ou

potencial de modelos LSTM baseados em dados. Destaca-se também a relevância da utilização de modelos orientados a dados como técnicas de *deep learning* com a possibilidade de auxiliar a simulação de vazão, especialmente em regiões em que a representação dos processos hidrológicos não se apresenta de uma forma linear e exigem modelos de maior complexidade do que uma estrutura convencional de modelagem hidrológica. Pesquisas futuras devem investigar outros regimes hidrológicos em ambientes tropicais e subtropicais.

5 CONCLUSÕES GERAIS

Esta tese forneceu uma avaliação abrangente da utilidade dos produtos de precipitação baseados em satélite e reanálise para estimativa da precipitação e vazão nas bacias hidrográficas brasileiras, e propôs um esquema de modelagem hidrológica regional com *deep learning* para aperfeiçoamento da simulação da vazão em bacias secas e úmidas. Os achados desse trabalho podem ser úteis para desenvolvimento de sistemas de monitoramento de precipitação e simulação da vazão, apoio a estudos hidrológicos e meteorológicos, avaliação de alterações climáticas, e auxílio à gestão e o gerenciamento dos recursos hídricos em bacias tropicais e subtropicais.

No Capítulo 2, os resultados evidenciaram que o desempenho da estimativa da precipitação dos produtos de satélite e reanálise depende das características de cada bioma e do sistema de precipitação, e os menores erros relativos são registrados durante a estação chuvosa. Além disso, a zona costeira da região Nordeste tende a subestimar a precipitação, e uma explicação para isso seria o predomínio de nuvens quentes que dificulta a detecção adequada da precipitação pelos sensores dos satélites.

No Capítulo 3 as descobertas destacaram as discrepâncias entre sete dados de precipitação baseados em satélite e reanálise para modelagem hidrológica em 714 bacias hidrográficas brasileiras no que diz respeito às regiões climáticas e à aridez. A modelagem hidrológica apresentou $KGE > 0,50$ para 78% das bacias hidrográficas. Os produtos de precipitação ERA5 e o MERRA-2 são os únicos que produzem estimativas subestimadas de precipitação para a maioria das bacias hidrográficas. Já os produtos de precipitação CHIRPS, IMERG e MERRA-2 apresentaram a melhor precisão em termos de estimativa de precipitação e desempenho de simulação hidrológica; além disso, os erros nos produtos de precipitação são melhor compensados através da modelagem hidrológica em regiões úmidas. E a sensibilidade dos parâmetros do modelo varia de acordo com a precipitação, clima e aridez da bacia hidrográfica.

Finalmente, o Capítulo 4 apresentou a utilidade de uma estrutura de modelagem orientada a dados que incorporam atributos climáticos, hidrológicos, topográficos, de cobertura do solo e de intervenção humana das bacias hidrográficas para aperfeiçoar a simulação da vazão em uma estrutura de modelagem hidrológica regionalizada em bacias úmidas e secas. O modelo hidrológico regional desenvolvido com *deep learning* permitiu obter estimativas precisas de vazão, em que cerca de 88% e 40% das bacias úmidas e secas, respectivamente, apresentaram valores de $KGE > 0.6$ no modelo regional de LSTM. As bacias hidrográficas úmidas apresentaram uma tendência mais acentuada de melhorar o desempenho com o aumento da

sequência dos eventos passados (*lookback*), evidenciando a existência de um processo hidrológico dominante de longo prazo nessas bacias, ao contrário do comportamento encontrado nas bacias secas, uma explicação para isso deve estar relacionada com as diferentes dinâmicas temporais subjacentes em cada regime. Os resultados também mostraram que o treinamento em nível regional teve um melhor desempenho geral e esses modelos são capazes de competir com os métodos baseados em uma modelagem hidrológica conceitual tradicional.

De modo geral, os conjuntos de dados de precipitação baseados em satélite e reanálise se apresentaram como alternativas potenciais para aplicações hidrológicas e monitoramento contínuo em bacias hidrográficas tropicais e subtropicais, especialmente em regiões com uma densidade relativamente escassa de estações de precipitação. No entanto, a incerteza associada a um determinado conjunto de dados de precipitação precisa ser tida em conta, considerando que a precipitação é um dos principais fatores que influenciam a simulação de chuva-vazão. Além disso, simulação da vazão em uma estrutura de modelagem hidrológica regionalizada com *deep learning* – LSTM – se mostrou promissora e muitos avanços ainda precisam ser feitos, como por exemplo a simulação da vazão nas bacias mais áridas do Brasil que permanece desafiadora.

Algumas recomendações e pesquisas podem ser derivadas dos estudos desenvolvidos na tese. Primeiramente, recomenda-se que pesquisas futuras, quando possível, utilizem séries temporais mais longas para reforçar a robustez do estudo. Trabalhos futuros poderiam centrar-se na avaliação do desempenho do fluxo sub-diário e dos eventos de inundação, utilizando conjuntos de dados de precipitação baseados em satélite e reanálise. Outra possibilidade também é avaliar estratégias de fusão de produtos de precipitação de múltiplas fontes para simulação de vazão. Em relação a modelagem orientada a dados, poderiam testar abordagens de hibridização de aprendizagem profunda com modelo conceitual para simular a vazão e estudos que avaliem a LSTM em outros regimes hidrológicos.

O avanço tecnológico e o crescimento exponencial da disponibilidade de dados na “era do *big data*”, aliados a algoritmos de inteligência artificial, têm um potencial real para fornecer novos *insights* sobre como as bacias hidrográficas funcionam e auxiliar a obtenção de estimativas precisas de precipitação e vazão nas bacias hidrográficas ao redor do globo. E ficou evidente, assim como demonstrado nos resultados dos capítulos, a utilidade dos dados de precipitação (baseados em satélite ou reanálise) e de inteligência artificial (LSTM) para estimativa da precipitação e vazão. Isso, por sua vez, auxiliará de maneira significativa a gestão e o gerenciamento dos recursos hídricos, especialmente em regiões caracterizadas pela escassez de dados, e pode alavancar o conhecimento e monitoramento das bacias tropicais e subtropicais.

REFERÊNCIAS

- ABATZOGLOU, John T. et al. TerraClimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958–2015. **Scientific data**, v. 5, n. 1, p. 1-12, 2018. <https://doi.org/10.1038/sdata.2017.191>.
- ABDI, Omid. Climate-triggered insect defoliators and forest fires using multitemporal Landsat and TerraClimate data in NE Iran: An application of GEOBIA TreeNet and panel data analysis. **Sensors**, v. 19, n. 18, p. 3965, 2019. <https://doi.org/10.3390/s19183965>.
- ADDOR, Nans et al. Large-sample hydrology: recent progress, guidelines for new datasets and grand challenges. **Hydrological Sciences Journal**, v. 65, n. 5, p. 712-725, 2020. <https://doi.org/10.1080/02626667.2019.1683182>.
- ADEYERI, O. E. et al. Conceptual hydrological model calibration using multi-objective optimization techniques over the transboundary Komadugu-Yobe basin, Lake Chad Area, West Africa. **Journal of Hydrology: Regional Studies**, v. 27, p. 100655, 2020. <https://doi.org/10.1016/j.ejrh.2019.100655>.
- AGHAKOUCHAK, Amir et al. Toward impact-based monitoring of drought and its cascading hazards. **Nature Reviews Earth & Environment**, v. 4, n. 8, p. 582-595, 2023.
- AHAMED, Aakash et al. Assessing the utility of remote sensing data to accurately estimate changes in groundwater storage. **Science of The Total Environment**, v. 807, p. 150635, 2022. <https://doi.org/10.1016/j.scitotenv.2021.150635>.
- ALFIERI, Lorenzo et al. A global network for operational flood risk reduction. **Environmental science & policy**, v. 84, p. 149-158, 2018. <https://doi.org/10.1016/j.envsci.2018.03.014>.
- ALFIERI, Lorenzo et al. High resolution satellite products improve hydrological modeling in northern Italy. **Hydrology and Earth System Sciences Discussions**, v. 2021, p. 1-29, 2021. <https://doi.org/10.5194/hess-26-3921-2022>.
- ALLEN, Richard G. et al. Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. **Fao, Rome**, v. 300, n. 9, p. D05109, 1998.
- ALMAGRO, André et al. Performance evaluation of Eta/HadGEM2-ES and Eta/MIROC5 precipitation simulations over Brazil. **Atmospheric Research**, v. 244, p. 105053, 2020. <https://doi.org/10.1016/j.atmosres.2020.105053>.
- ALMAGRO, André et al. CABra: a novel large-sample dataset for Brazilian catchments. **Hydrology and Earth System Sciences**, v. 25, n. 6, p. 3105-3135, 2021a. <https://doi.org/10.5194/hess-25-3105-2021>.
- ALMAGRO, André; OLIVEIRA, Paulo Tarso Sanches; BROCCA, Luca. Assessment of bottom-up satellite rainfall products on estimating river discharge and hydrologic signatures

in Brazilian catchments. **Journal of Hydrology**, v. 603, p. 126897, 2021b. doi:10.1016/j.jhydrol.2021.126897.

ALTHOFF, Daniel; RODRIGUES, Lineu Neiva; DA SILVA, Demetrius David. Addressing hydrological modeling in watersheds under land cover change with deep learning. **Advances in Water Resources**, v. 154, p. 103965, 2021. <https://doi.org/10.1016/j.advwatres.2021.103965>.

ALVARES, Clayton Alcarde et al. Köppen's climate classification map for Brazil. **Meteorologische zeitschrift**, v. 22, n. 6, p. 711-728, 2013. <https://doi.org/10.1127/0941-2948/2013/0507>.

ANA, Agência Nacional de Águas e Saneamento Básico (2020). USO DA ÁGUA NA AGRICULTURA DE SEQUEIRO NO BRASIL (2013-2017). ANA., Brasília-DF, pp.1-63. https://biblioteca.ana.gov.br/sophia_web/acervo/detalhe/82410. Acessado em: 02 Set de 2022.

ANDRADE, João M. et al. Evaluating single and multi-date Landsat classifications of land-cover in a seasonally dry tropical forest. **Remote Sensing Applications: Society and Environment**, v. 22, p. 100515, 2021. <https://doi.org/10.1016/j.rsase.2021.100515>.

ANDRADE, João M. et al. A comprehensive assessment of precipitation products: temporal and spatial analyses over terrestrial biomes in Northeastern Brazil. **Remote Sensing Applications: Society and Environment**, v. 28, p. 100842, 2022. <https://doi.org/10.1016/j.rsase.2022.100842>.

ANDRADE, João M. et al. Efficiency of global precipitation datasets in tropical and subtropical catchments revealed by large sampling hydrological modelling. **Journal of Hydrology**, v. 633, p. 131016, 2024. <https://doi.org/10.1016/j.jhydrol.2024.131016>.

ARHEIMER, Berit et al. Global catchment modelling using World-Wide HYPE (WWH), open data, and stepwise parameter estimation. **Hydrology and Earth System Sciences**, v. 24, n. 2, p. 535-559, 2020. <https://doi.org/10.5194/hess-24-535-2020>.

ARORA, Vivek K. The use of the aridity index to assess climate change effect on annual runoff. **Journal of hydrology**, v. 265, n. 1-4, p. 164-177, 2002. [https://doi.org/10.1016/S0022-1694\(02\)00101-4](https://doi.org/10.1016/S0022-1694(02)00101-4).

ARSHAD, Muhammad et al. Evaluation of GPM-IMERG and TRMM-3B42 precipitation products over Pakistan. **Atmospheric Research**, v. 249, p. 105341, 2021. <https://doi.org/10.1016/j.atmosres.2020.105341>.

ARSENAULT, Richard et al. Continuous streamflow prediction in ungauged basins: long short-term memory neural networks clearly outperform traditional hydrological models. **Hydrology and Earth System Sciences**, v. 27, n. 1, p. 139-157, 2023. <https://doi.org/10.5194/hess-27-139-2023>.

AYZEL, Georgy; HEISTERMANN, Maik. The effect of calibration data length on the performance of a conceptual hydrological model versus LSTM and GRU: A case study for six basins from the CAMELS dataset. **Computers & Geosciences**, v. 149, p. 104708, 2021. <https://doi.org/10.1016/j.cageo.2021.104708>.

BAETHGEN, Walter E.; GODDARD, Lisa. Latin American perspectives on adaptation of agricultural systems to climate variability and change. In: *Handbook of Climate Change and Agroecosystems: Global and Regional Aspects and Implications—Joint Publication with the American Society of Agronomy, Crop Science Society of America, and Soil Science Society of America*. 2013. p. 57-72.

BAI, Peng; LIU, Xiaomang; XIE, Jiaxin. Simulating runoff under changing climatic conditions: a comparison of the long short-term memory network with two conceptual hydrologic models. *Journal of Hydrology*, v. 592, p. 125779, 2021. <https://doi.org/10.1016/j.jhydrol.2020.125779>

BARBOSA, H. A.; KUMAR, TV Lakshmi. Influence of rainfall variability on the vegetation dynamics over Northeastern Brazil. *Journal of Arid Environments*, v. 124, p. 377-387, 2016. <https://doi.org/10.1016/j.jaridenv.2015.08.015>.

BASTIAANSEN, Wim; LAN, H. T.; FENN, Mark. Water Accounting Plus (WA+) for Reporting Water Resources Conditions and Management: A Case Study in the Ca River Basin, Vietnam. 2015.

BEAUDOING, H., & RODELL, M. GLDAS Noah Land Surface Model L4 3 hourly 0.25 x 0.25 degree V2.1. NASA/GSFC/HSL, Greenbelt, Maryland, USA. *Goddard Earth Sciences Data and Information Services Center (GES DISC)*, 2020. <https://doi.org/10.5067/E7TYRXPJKWOQ>.

BECK, Hylke E. et al. Global-scale evaluation of 22 precipitation datasets using gauge observations and hydrological modeling. *Hydrology and Earth System Sciences*, v. 21, n. 12, p. 6201-6217, 2017. <https://doi.org/10.5194/hess-21-6201-2017>.

BERGHUIJS, Wouter R. et al. Global recharge data set indicates strengthened groundwater connection to surface fluxes. *Geophysical Research Letters*, v. 49, n. 23, p. e2022GL099010, 2022. <https://doi.org/10.1029/2022GL099010>.

BEVEN, Keith. Towards an alternative blueprint for a physically based digitally simulated hydrologic response modelling system. *Hydrological processes*, v. 16, n. 2, p. 189-206, 2002. <https://doi.org/10.1002/hyp.343>.

BEVEN, Keith. Deep learning, hydrological processes and the uniqueness of place. *Hydrological Processes*, v. 34, n. 16, 2020. <https://doi.org/10.1002/hyp.13805>.

BEVACQUA, Alena G. et al. Spatial and temporal patterns of propagation from meteorological to hydrological droughts in Brazil. *Journal of Hydrology*, v. 603, p. 126902, 2021. <https://doi.org/10.1016/j.jhydrol.2021.126902>.

BEUCHLE, René et al. Land cover changes in the Brazilian Cerrado and Caatinga biomes from 1990 to 2010 based on a systematic remote sensing sampling approach. *Applied Geography*, v. 58, p. 116-127, 2015. <https://doi.org/10.1016/j.apgeog.2015.01.017>.

BLÖSCHL, Günter; SIVAPALAN, Murugesu. Scale issues in hydrological modelling: a review. *Hydrological processes*, v. 9, n. 3-4, p. 251-290, 1995. <https://doi.org/10.1002/hyp.3360090305>.

BORETTI, Alberto; ROSA, Lorenzo. Reassessing the projections of the world water development report. **NPJ Clean Water**, v. 2, n. 1, p. 15, 2019. <https://doi.org/10.1038/s41545-019-0039-9>.

BRITO, Célia Soares et al. Monitoring meteorological drought in a semiarid region using two long-term satellite-estimated rainfall datasets: A case study of the Piranhas River basin, northeastern Brazil. **Atmospheric Research**, v. 250, p. 105380, 2021. <https://doi.org/10.1016/j.atmosres.2020.105380>.

BRITO, Célia Soares et al. Long-term basin-scale comparison of two high-resolution satellite-based remote sensing datasets for assessing rainfall and erosivity in a basin in the Brazilian semiarid region. **Theoretical and Applied Climatology**, v. 147, n. 3, p. 1049-1064, 2022. <https://doi.org/10.1007/s00704-021-03857-w>.

BRIGHENTI, Tássia Mattos et al. Two calibration methods for modeling streamflow and suspended sediment with the swat model. **Ecological Engineering**, v. 127, p. 103-113, 2019. <https://doi.org/10.1016/j.ecoleng.2018.11.007>.

BROCCA, Luca et al. River flow prediction in data scarce regions: soil moisture integrated satellite rainfall products outperform rain gauge observations in West Africa. **Scientific Reports**, v. 10, n. 1, p. 12517, 2020. <https://doi.org/10.1038/s41598-020-69343-x>.

BYTHEWAY, Janice L.; KUMMEROW, Christian D. A physically based screen for precipitation over complex surfaces using passive microwave observations. **IEEE transactions on geoscience and remote sensing**, v. 48, n. 1, p. 299-313, 2009. <https://doi.org/10.1109/tgrs.2009.2027434>.

CAMICI, Stefania et al. How reliable are satellite precipitation estimates for driving hydrological models: A verification study over the Mediterranean area. **Journal of hydrology**, v. 563, p. 950-961, 2018. <https://doi.org/10.1016/j.jhydrol.2018.06.067>.

CAMICI, Stefania et al. Which rainfall score is more informative about the performance in river discharge simulation? A comprehensive assessment on 1318 basins over Europe. **Hydrology and Earth System Sciences**, v. 24, n. 10, p. 4869-4885, 2020. <https://doi.org/10.5194/hess-24-4869-2020>.

CANTONI, Elia et al. Hydrological performance of the ERA5 reanalysis for flood modeling in Tunisia with the LISFLOOD and GR4J models. **Journal of Hydrology: Regional Studies**, v. 42, p. 101169, 2022. <https://doi.org/10.1016/j.ejrh.2022.101169>.

CAVALCANTE, Rosane Barbosa Lopes et al. Evaluation of extreme rainfall indices from CHIRPS precipitation estimates over the Brazilian Amazonia. **Atmospheric Research**, v. 238, p. 104879, 2020. <https://doi.org/10.1016/j.atmosres.2020.104879>.

CHAGAS JUNIOR, Francisco das Vasconcelos et al. An attribution study of very intense rainfall events in Eastern Northeast Brazil. **Weather and Climate Extremes**, p. 100699, 2024. <https://doi.org/10.1016/j.wace.2024.100699>.

CHAGAS, Vinícius BP et al. CAMELS-BR: hydrometeorological time series and landscape attributes for 897 catchments in Brazil. **Earth System Science Data**, v. 12, n. 3, p. 2075-2096, 2020. <https://doi.org/10.5194/essd-12-2075-2020>.

CHAGAS, Vinicius BP; CHAFFE, Pedro LB; BLÖSCHL, Günter. Regional low flow hydrology: Model development and evaluation. **Water Resources Research**, v. 60, n. 2, p. e2023WR035063, 2024. <https://doi.org/10.1029/2023WR035063>.

CHEN, Lajiao; WANG, Lizhe. Recent advance in earth observation big data for hydrology. **Big Earth Data**, v. 2, n. 1, p. 86-107, 2018. <https://doi.org/10.1080/20964471.2018.1435072>.

CHOLLET, Francois. **Deep learning mit python und keras: das praxis-handbuch vom entwickler der keras-bibliothek**. MITP-Verlags GmbH & Co. KG, 2018.

CORON, Laurent et al. airGR: Suite of GR Hydrological Models for Precipitation-Runoff Modelling. **R package version 1.0**. 13.19. 2018.

CORON, Laurent et al. The suite of lumped GR hydrological models in an R package. **Environmental modelling & software**, v. 94, p. 166-171, 2017. doi:10.1016/j.envsoft.2017.05.002.

COSTA, Alexandre Araújo et al. Microphysical observations of warm cumulus clouds in Ceara, Brazil. **Atmospheric Research**, v. 54, n. 2-3, p. 167-199, 2000. [https://doi.org/10.1016/S0169-8095\(00\)00045-4](https://doi.org/10.1016/S0169-8095(00)00045-4).

COSTA, Rafaela Lisboa et al. Analysis of climate extremes indices over northeast Brazil from 1961 to 2014. **Weather and Climate Extremes**, v. 28, p. 100254, 2020. <https://doi.org/10.1016/j.wace.2020.100254>.

CUNHA, A. P. M. et al. Monitoring vegetative drought dynamics in the Brazilian semiarid region. **Agricultural and forest meteorology**, v. 214, p. 494-505, 2015. <https://doi.org/10.1016/j.agrformet.2015.09.010>.

CUNHA, Ana Paula MA et al. Extreme drought events over Brazil from 2011 to 2019. **Atmosphere**, v. 10, n. 11, p. 642, 2019. <https://doi.org/10.3390/atmos10110642>.

DAHRI, Zakir Hussain et al. Adjustment of measurement errors to reconcile precipitation distribution in the high-altitude Indus basin. **International Journal of Climatology** 2018; 38: 3842–3860., 2018. <https://doi.org/10.1002/joc.5539>.

DELANEY, Chris J. et al. Forecast informed reservoir operations using ensemble streamflow predictions for a multipurpose reservoir in Northern California. **Water Resources Research**, v. 56, n. 9, p. e2019WR026604, 2020. <https://doi.org/10.1029/2019WR026604>.

DEMBÉLÉ, Moctar; ZWART, Sander J. Evaluation and comparison of satellite-based rainfall products in Burkina Faso, West Africa. **International Journal of Remote Sensing**, v. 37, n. 17, p. 3995-4014, 2016. <https://doi.org/10.1080/01431161.2016.1207258>.

DERIN, Yagmur et al. Evaluation of IMERG satellite precipitation over the land–coast–ocean continuum. Part II: Quantification. **Journal of Hydrometeorology**, v. 23, n. 8, p. 1297-1314, 2022. <https://doi.org/10.1175/JHM-D-21-0234.1>.

DINIZ, João Alberto Oliveira et al. Mapa hidrogeológico do Brasil ao milionésimo: nota técnica. **CPRM**, 2014.

DINKU, Tufa; CECCATO, Pietro; CONNOR, Stephen J. Challenges of satellite rainfall estimation over mountainous and arid parts of east Africa. **International journal of remote sensing**, v. 32, n. 21, p. 5965-5979, 2011. <https://doi.org/10.1080/01431161.2010.499381>.

DUAN, Zheng et al. Evaluation of eight high spatial resolution gridded precipitation products in Adige Basin (Italy) at multiple temporal and spatial scales. **Science of the Total Environment**, v. 573, p. 1536-1553, 2016. <https://doi.org/10.1016/j.scitotenv.2016.08.213>.

DUARTE, Leandro Da Silva et al. Phylobetadiversity among forest types in the Brazilian Atlantic Forest complex. **PloS one**, v. 9, n. 8, p. e105043, 2014. <https://doi.org/10.1371/journal.pone.0105043>.

DUBEY, Saket et al. Evaluation of precipitation datasets available on Google earth engine over India. **International Journal of Climatology**, v. 41, n. 10, p. 4844-4863, 2021. <https://doi.org/10.1002/joc.7102>.

ECKSTEIN, David; HUTFILS, Marie-Lena; WINGES, Maik. Global climate risk index 2019. **Who suffers most from extreme weather events**, v. 36, 2018.

FALCK, Aline S. et al. Propagation of satellite precipitation uncertainties through a distributed hydrologic model: A case study in the Tocantins–Araguaia basin in Brazil. **Journal of Hydrology**, v. 527, p. 943-957, 2015. <https://doi.org/10.1016/j.jhydrol.2015.05.042>.

FAN, Hongxiang et al. Comparison of long short term memory networks and the hydrological model in runoff simulation. **Water**, v. 12, n. 1, p. 175, 2020. <https://doi.org/10.3390/w12010175>.

FERREIRA, Paloma Mara de Lima; PAZ, Adriano Rolim da; BRAVO, Juan Martín. Funções-objetivo utilizadas como medidas de desempenho de modelos hidrológicos: estado-da-arte e análise crítica. **RBRH**, v. 25, p. e42, 2020. <https://doi.org/10.1590/2318-0331.252020190155>.

FREITAS, Emerson da S. et al. The performance of the IMERG satellite-based product in identifying sub-daily rainfall events and their properties. **Journal of Hydrology**, v. 589, p. 125128, 2020. <https://doi.org/10.1016/j.jhydrol.2020.125128>.

FUNK, Chris et al. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. **Scientific data**, v. 2, n. 1, p. 1-21, 2015. <https://doi.org/10.1038/sdata.2015.66>.

GADELHA, André N. et al. Grid box-level evaluation of IMERG over Brazil at various space and time scales. **Atmospheric Research**, v. 218, p. 231-244, 2019. <https://doi.org/10.1016/j.atmosres.2018.12.001>.

GALEANO, Eduardo. **Os filhos dos dias**. L&PM Editores, 2012.

GAUCH, Martin; MAI, Juliane; LIN, Jimmy. The proper care and feeding of CAMELS: How limited training data affects streamflow prediction. **Environmental Modelling & Software**, v. 135, p. 104926, 2021. <https://doi.org/10.1016/j.envsoft.2020.104926>.

GELARO, Ronald et al. The modern-era retrospective analysis for research and applications, version 2 (MERRA-2). **Journal of climate**, v. 30, n. 14, p. 5419-5454, 2017. <https://doi.org/10.1175/JCLI-D-16-0758.1>.

GETIRANA, Augusto. Extreme water deficit in Brazil detected from space. **Journal of Hydrometeorology**, v. 17, n. 2, p. 591-599, 2016. <https://doi.org/10.1175/JHM-D-15-0096.1>.

GETIRANA, Augusto; LIBONATI, Renata; CATALDI, Marcio. Brazil is in water crisis—it needs a drought plan. **Nature**, 600, pp. 218-220, 2021. <https://doi.org/10.1038/d41586-021-03625-w>.

GOODFELLOW, I., Bengio, Y., & Courville, A. Deep learning. **MIT press**, 2016.

GORELICK, Noel et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote sensing of Environment**, v. 202, p. 18-27, 2017. <https://doi.org/10.1016/j.rse.2017.06.031>.

GUO, Binbin et al. Multiple spatial and temporal scales evaluation of eight satellite precipitation products in a mountainous catchment of south China. **Remote Sensing**, v. 15, n. 5, p. 1373, 2023. <https://doi.org/10.3390/rs15051373>.

GUPTA, Hoshin V. et al. Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. **Journal of hydrology**, v. 377, n. 1-2, p. 80-91, 2009. <https://doi.org/10.1016/j.jhydrol.2009.08.003>.

GUPTA, H. V. et al. Large-sample hydrology: a need to balance depth with breadth. **Hydrology and Earth System Sciences**, v. 18, n. 2, p. 463-477, 2014. <https://doi.org/10.5194/hess-18-463-2014>.

HAPUARACHCHI, Hapu Arachchige Prasantha et al. Development of a national 7-day ensemble streamflow forecasting service for Australia. **Hydrology and Earth System Sciences**, v. 26, n. 18, p. 4801-4821, 2022. <https://doi.org/10.5194/hess-26-4801-2022>.

HASHEMI, Reyhaneh et al. How can we benefit from regime information to make more effective use of long short-term memory (LSTM) runoff models?. **Hydrology and Earth System Sciences**, v. 26, n. 22, p. 5793-5816, 2022. <https://doi.org/10.5194/hess-26-5793-2022>.

HERSBACH, Hans et al. The ERA5 global reanalysis. **Quarterly Journal of the Royal Meteorological Society**, v. 146, n. 730, p. 1999-2049, 2020. <https://doi.org/10.1002/qj.3803>.

HOBOUCHIAN, María Paula et al. Assessment of satellite precipitation estimates over the slopes of the subtropical Andes. **Atmospheric Research**, v. 190, p. 43-54, 2017. <https://doi.org/10.1016/j.atmosres.2017.02.006>.

HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long short-term memory. **Neural computation**, v. 9, n. 8, p. 1735-1780, 1997. <https://doi.org/10.1162/neco.1997.9.8.1735>.

HOCHREITER, Sepp. The vanishing gradient problem during learning recurrent neural nets and problem solutions. International Journal of Uncertainty, **Fuzziness and Knowledge-Based Systems**, v. 6, n. 02, p. 107-116, 1998. <https://doi.org/10.1142/S0218488598000094>.

HORTON, Pascal; SCHAEFLI, Bettina; KAUZLARIC, Martina. Why do we have so many different hydrological models? A review based on the case of Switzerland. **Wiley Interdisciplinary Reviews: Water**, v. 9, n. 1, p. e1574, 2022. <https://doi.org/10.1002/wat2.1574>.

HUFFMAN, George J. et al. The TRMM multisatellite precipitation analysis (TMPA): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. **Journal of hydrometeorology**, v. 8, n. 1, p. 38-55, 2007. <https://doi.org/10.1175/JHM560.1>.

HUFFMAN, G. J., Stocker, E. F., Bolvin, D. T., Nelkin, E. J., & Tan, J. (2019). GPM IMERG final precipitation L3 half hourly 0.1 degree x 0.1 degree V06. Greenbelt, MD, Goddard Earth Sciences Data and Information Services Center (GES DISC). Acessado em: 17 Set. 2021, doi:10.5067/GPM/IMERG/3B-HH/06.

HUMPHREY, Greer B. et al. A hybrid approach to monthly streamflow forecasting: integrating hydrological model outputs into a Bayesian artificial neural network. **Journal of Hydrology**, v. 540, p. 623-640, 2016.

HURTADO, Santiago I. et al. Infilling methods for monthly precipitation records with poor station network density in Subtropical Argentina. **Atmospheric Research**, v. 254, p. 105482, 2021. <https://doi.org/10.1175/JHM560.1>.

IBGE, Instituto Brasileiro de Geografia e Estatística (2019). Censo Agropecuário 2017: Resultados Definitivos. **Censo agropec.**, Rio de Janeiro, vol. 8, pp.1-105. Disponível em: https://biblioteca.ibge.gov.br/visualizacao/periodicos/3096/agro_2017_resultados_definitivos.pdf. Acesso em: 2 set. 2022.

IOOSS, Bertrand et al. Sensitivity: global sensitivity analysis of model outputs. **R package version**, v. 1, n. 0, 2021.

IZADI, Ardalan et al. Exploring the potential of deep learning for streamflow forecasting: A comparative study with hydrological models for seasonal and perennial rivers. **Expert Systems with Applications**, v. 252, p. 124139, 2024. <https://doi.org/10.1016/j.eswa.2024.124139>.

JAJARMIZADEH, Milad; HARUN, Sobri; SALARPOUR, Mohsen. A review on theoretical consideration and types of models in hydrology. **Journal of Environmental Science and Technology**, v. 5, n. 5, p. 249-261, 2012.

JIANG, Liguang; BAUER-GOTTWEIN, Peter. How do GPM IMERG precipitation estimates perform as hydrological model forcing? Evaluation for 300 catchments across Mainland China. **Journal of Hydrology**, v. 572, p. 486-500, 2019. <https://doi.org/10.1016/j.jhydrol.2019.03.042>.

JUNQUEIRA, Rubens et al. Hydrological modeling using remote sensing precipitation data in a Brazilian savanna basin. **Journal of South American Earth Sciences**, v. 115, p. 103773, 2022. <https://doi.org/10.1016/j.jsames.2022.103773>.

KATSANOS, Dimitrios; RETALIS, Adrianos; MICHAELIDES, Silas. Validation of a high-resolution precipitation database (CHIRPS) over Cyprus for a 30-year period. **Atmospheric Research**, v. 169, p. 459-464, 2016. <https://doi.org/10.1016/j.atmosres.2015.05.015>.

KHAND, Kul; SENAY, Gabriel B. Evaluation of streamflow predictions from LSTM models in water-and energy-limited regions in the United States. **Machine Learning with Applications**, v. 16, p. 100551, 2024. <https://doi.org/10.1016/j.mlwa.2024.100551>.

KHATAKHO, Rajesh; TALCHABHADEL, Rocky; THAPA, Bhesh Raj. Evaluation of different precipitation inputs on streamflow simulation in Himalayan River basin. **Journal of Hydrology**, v. 599, p. 126390, 2021. <https://doi.org/10.1016/j.jhydrol.2021.126390>.

KIDD, Chris; HUFFMAN, George. Global precipitation measurement. **Meteorological Applications**, v. 18, n. 3, p. 334-353, 2011. <https://doi.org/10.1002/met.284>.

KIDD, Chris et al. So, how much of the Earth's surface is covered by rain gauges?. **Bulletin of the American Meteorological Society**, v. 98, n. 1, p. 69-78, 2017. <https://doi.org/10.1175/BAMS-D-14-00283.1>.

KINGMA, Diederik P.; BA, Jimmy. Adam: A method for stochastic optimization. **arXiv preprint arXiv:1412.6980**, 2014. <https://doi.org/10.48550/arXiv.1412.6980>.

KIRSCHBAUM, Dalia B. et al. NASA's remotely sensed precipitation: A reservoir for applications users. **Bulletin of the American Meteorological Society**, v. 98, n. 6, p. 1169-1184, 2017. <https://doi.org/10.1175/BAMS-D-15-00296.1>.

KLINGLER, Christoph; SCHULZ, Karsten; HERRNEGGER, Mathew. LamaH| Large-Sample Data for Hydrology and Environmental Sciences for Central Europe. **Earth System Science Data Discussions**, v. 2021, p. 1-46, 2021. <https://doi.org/10.5194/essd-13-4529-2021>.

KNOBEN, Wouter JM; FREER, Jim E.; WOODS, Ross A. Inherent benchmark or not? Comparing Nash–Sutcliffe and Kling–Gupta efficiency scores. **Hydrology and Earth System Sciences**, v. 23, n. 10, p. 4323-4331, 2019. <https://doi.org/10.5194/hess-23-4323-2019>.

KRATZERT, Frederik et al. Rainfall–runoff modelling using long short-term memory (LSTM) networks. **Hydrology and Earth System Sciences**, v. 22, n. 11, p. 6005-6022, 2018. <https://doi.org/10.5194/hess-22-6005-2018>.

KRATZERT, Frederik et al. Toward improved predictions in ungauged basins: Exploiting the power of machine learning. **Water Resources Research**, v. 55, n. 12, p. 11344-11354, 2019. <https://doi.org/10.1029/2019WR026065>.

KRATZERT, Frederik et al. Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets. **Hydrology and Earth System Sciences**, v. 23, n. 12, p. 5089-5110, 2019. <https://doi.org/10.5194/hess-23-5089-2019>.

LEVIS, Carolina et al. Help restore Brazil's governance of globally important ecosystem services. **Nature Ecology & Evolution**, v. 4, n. 2, p. 172-173, 2020. <https://doi.org/10.1038/s41559-019-1093-x>.

LI, Xiang-Hu; ZHANG, Qi; XU, Chong-Yu. Suitability of the TRMM satellite rainfalls in driving a distributed hydrological model for water balance computations in Xinjiang catchment, Poyang lake basin. **Journal of Hydrology**, v. 426, p. 28-38, 2012. <https://doi.org/10.1016/j.jhydrol.2012.01.013>.

LI, Xiang et al. Regionalization in a global hydrologic deep learning model: from physical descriptors to random vectors. **Water Resources Research**, v. 58, n. 8, p. e2021WR031794, 2022. <https://doi.org/10.1029/2021WR031794>.

LININGER, Katherine B.; LATRUBESSE, Edgardo M. Flooding hydrology and peak discharge attenuation along the middle Araguaia River in central Brazil. **Catena**, v. 143, p. 90-101, 2016. <https://doi.org/10.1016/j.catena.2016.03.043>.

LONGO-MINNOLO, Giuseppe et al. Assessing the use of ERA5-Land reanalysis and spatial interpolation methods for retrieving precipitation estimates at basin scale. **Atmospheric Research**, v. 271, p. 106131, 2022. <https://doi.org/10.1016/j.atmosres.2022.106131>.

LOPEZ, Philippe. Direct 4D-Var assimilation of NCEP stage IV radar and gauge precipitation data at ECMWF. **Monthly Weather Review**, v. 139, n. 7, p. 2098-2116, 2011. <https://doi.org/10.1175/2010MWR3565.1>.

LUCAS, Murilo Cesar et al. Significant baseflow reduction in the sao francisco river basin. **Water**, v. 13, n. 1, p. 2, 2021. <https://doi.org/10.3390/w13010002>.

LUCENA, Daisy Beserra; GOMES FILHO, Manoel F.; SERVAIN, Jacques. Avaliação do impacto de eventos climáticos extremos nos Oceanos Pacífico e Atlântico sobre a estação chuvosa no nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 26, p. 297-312, 2011. <https://doi.org/10.1590/S0102-77862011000200013>.

LUO, Xian et al. Hydrological simulation using TRMM and CHIRPS precipitation estimates in the lower Lancang-Mekong river basin. **Chinese geographical science**, v. 29, p. 13-25, 2019. <https://doi.org/10.1007/s11769-019-1014-6>.

MAGGIONI, Viviana et al. An error model for uncertainty quantification in high-time-resolution precipitation products. **Journal of Hydrometeorology**, v. 15, n. 3, p. 1274-1292, 2014. <https://doi.org/10.1175/JHM-D-13-0112.1>.

- MAGGIONI, Viviana; MEYERS, Patrick C.; ROBINSON, Monique D. A review of merged high-resolution satellite precipitation product accuracy during the Tropical Rainfall Measuring Mission (TRMM) era. **Journal of Hydrometeorology**, v. 17, n. 4, p. 1101-1117, 2016. <https://doi.org/10.1175/JHM-D-15-0190.1>.
- MAGGIONI, Viviana; MASSARI, Christian. On the performance of satellite precipitation products in riverine flood modeling: A review. **Journal of hydrology**, v. 558, p. 214-224, 2018. <https://doi.org/10.1016/j.jhydrol.2018.01.039>.
- MAI, Juliane et al. The great lakes runoff intercomparison project phase 4: the great lakes (GRIP-GL). **Hydrology and Earth System Sciences**, v. 26, n. 13, p. 3537-3572, 2022. <https://doi.org/10.5194/hess-26-3537-2022>.
- MARENGO, Jose A.; TORRES, Roger Rodrigues; ALVES, Lincoln Muniz. Drought in Northeast Brazil—past, present, and future. **Theoretical and Applied Climatology**, v. 129, p. 1189-1200, 2017. <https://doi.org/10.1007/s00704-016-1840-8>.
- MARTINS, Minella Alves; TOMASELLA, Javier; DIAS, Cássia Gabriele. Maize yield under a changing climate in the Brazilian Northeast: impacts and adaptation. **Agricultural water management**, v. 216, p. 339-350, 2019. <https://doi.org/10.1016/j.agwat.2019.02.011>.
- MEDEIROS, Rodolpho et al. Remote sensing phenology of the Brazilian caatinga and its environmental drivers. **Remote Sensing**, v. 14, n. 11, p. 2637, 2022. <https://doi.org/10.3390/rs14112637>.
- MELO, Davi de CD et al. Performance evaluation of rainfall estimates by TRMM Multi-satellite Precipitation Analysis 3B42V6 and V7 over Brazil. **Journal of Geophysical Research: Atmospheres**, v. 120, n. 18, p. 9426-9436, 2015. <https://doi.org/10.1002/2015JD023797>.
- MESSAGER, Mathis Loïc et al. Global prevalence of non-perennial rivers and streams. **Nature**, v. 594, n. 7863, p. 391-397, 2021. <https://doi.org/10.1038/s41586-021-03565-5>.
- MICHEL, Claude. **Hydrologie appliquée aux petits bassins ruraux**. Centre national du machinisme agricole, du génie rural, des eaux et des forêts (CEMAGREF), 1987.
- MITRA, A. K. et al. Evaluation of INSAT-3D satellite derived precipitation estimates for heavy rainfall events and its validation with gridded GPM (IMERG) rainfall dataset over the Indian region. **Remote sensing applications: Society and environment**, v. 9, p. 91-99, 2018. <https://doi.org/10.1016/j.rsase.2017.12.006>.
- MIZUKAMI, Naoki et al. On the choice of calibration metrics for “high-flow” estimation using hydrologic models. **Hydrology and Earth System Sciences**, v. 23, n. 6, p. 2601-2614, 2019. <https://doi.org/10.5194/hess-23-2601-2019>.
- MOGES, Desalew Meseret; KMOCH, Alexander; UUEMAA, Evelyn. Application of satellite and reanalysis precipitation products for hydrological modeling in the data-scarce Porijõgi catchment, Estonia. **Journal of Hydrology: Regional Studies**, v. 41, p. 101070, 2022. <https://doi.org/10.1016/j.ejrh.2022.101070>.

MOHAMMADI, Babak; SAFARI, Mir Jafar Sadegh; VAZIFEHKHAH, Saeed. IHACRES, GR4J and MISD-based multi conceptual-machine learning approach for rainfall-runoff modeling. **Scientific Reports**, v. 12, n. 1, p. 12096, 2022. <https://doi.org/10.1038/s41598-022-16215-1>.

MOKHTARI, Shirin; SHARAFATI, Ahmad; RAZIEI, Tayeb. Satellite-based streamflow simulation using CHIRPS satellite precipitation product in Shah Bahram Basin, Iran. **Acta Geophysica**, v. 70, n. 1, p. 385-398, 2022. <https://doi.org/10.1007/s11600-021-00724-0>.

MTIBAA, Slim; ASANO, Shiho. Hydrological evaluation of radar and satellite gauge-merged precipitation datasets using the SWAT model: Case of the Terauchi catchment in Japan. **Journal of Hydrology: Regional Studies**, v. 42, p. 101134, 2022. <https://doi.org/10.1016/j.ejrh.2022.101134>.

MU, Ye; BIGGS, Trent; SHEN, Samuel SP. Satellite-based precipitation estimates using a dense rain gauge network over the Southwestern Brazilian Amazon: Implication for identifying trends in dry season rainfall. **Atmospheric Research**, v. 261, p. 105741, 2021. <https://doi.org/10.1016/j.atmosres.2021.105741>.

MUÑOZ SABATER, J., (2019): ERA5-Land hourly data from 1981 to present. **Copernicus Climate Change Service (C3S) Climate Data Store (CDS)**. Acessado em: 10 September 2021, doi:10.24381/cds.e2161bac.

NASH, J. Eamonn; SUTCLIFFE, Jonh V. River flow forecasting through conceptual models part I—A discussion of principles. **Journal of hydrology**, v. 10, n. 3, p. 282-290, 1970. doi:10.1016/0022-1694(70)90255-6.

NAYAK, A. K.; BISWAL, B.; SUDHEER, K. P. Role of hydrological model structure in the assimilation of soil moisture for streamflow prediction. **Journal of Hydrology**, v. 598, p. 126465, 2021. <https://doi.org/10.1016/j.jhydrol.2021.126465>.

NAZEER, Aftab et al. Simulating the hydrological regime of the snow fed and glacierised Gilgit Basin in the Upper Indus using global precipitation products and a data parsimonious precipitation-runoff model. **Science of the Total Environment**, v. 802, p. 149872, 2022. <https://doi.org/10.1016/j.scitotenv.2021.149872>.

NELSON, Donald R.; FINAN, Timothy J. Praying for drought: persistent vulnerability and the politics of patronage in Ceará, Northeast Brazil. **American Anthropologist**, p. 302-316, 2009. <https://doi.org/10.1111/j.1548-1433.2009.01134.x>.

NOGUEIRA FILHO, Francisco José Matos et al. Deep learning for streamflow regionalization for ungauged basins: Application of long-short-term-memory cells in Semiarid regions. **Water**, v. 14, n. 9, p. 1318, 2022. <https://doi.org/10.3390/w14091318>.

NOGUEIRA, C. Sulimar Munira; MOREIRA, Maurício Alves; LORDELO VOLPATO, Margarete Marin. Evaluating precipitation estimates from Eta, TRMM and CHIRPS Data in the south-southeast region of Minas Gerais State—Brazil. **Remote Sensing**, v. 10, n. 2, p. 313, 2018. <https://doi.org/10.3390/rs10020313>.

- NASCIMENTO, Jéssica et al. Evaluating the latest IMERG products in a subtropical climate: The case of Paraná State, Brazil. **Remote Sensing**, v. 13, n. 5, p. 906, 2021. <https://doi.org/10.3390/rs13050906>.
- NOORI, Navideh; KALIN, Latif. Coupling SWAT and ANN models for enhanced daily streamflow prediction. **Journal of Hydrology**, v. 533, p. 141-151, 2016. <https://doi.org/10.1016/j.jhydrol.2015.11.050>.
- OKI, Taikan; KANAE, Shinjiro. Global hydrological cycles and world water resources. **Science**, v. 313, n. 5790, p. 1068-1072, 2006. DOI: 10.1126/science.1128845.
- OKKAN, Umut et al. Embedding machine learning techniques into a conceptual model to improve monthly runoff simulation: A nested hybrid rainfall-runoff modeling. **Journal of Hydrology**, v. 598, p. 126433, 2021. <https://doi.org/10.1016/j.jhydrol.2021.126433>.
- OLAH, Christopher et al. Understanding lstm networks. **Colah's blog**. 2015. Disponível em: < <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>>. Acessado em: 10 de Jun. 2024.
- OLIVEIRA, PT de; SANTOS E SILVA, C. M.; LIMA, Kellen Carla. Climatology and trend analysis of extreme precipitation in subregions of Northeast Brazil. **Theoretical and Applied Climatology**, v. 130, p. 77-90, 2017. <https://doi.org/10.1007/s00704-016-1865-z>.
- OLIVEIRA, Rômulo et al. Using satellite error modeling to improve GPM-Level 3 rainfall estimates over the central Amazon region. **Remote Sensing**, v. 10, n. 2, p. 336, 2018. <https://doi.org/10.3390/rs10020336>.
- OLIVEIRA-JÚNIOR, José Francisco et al. Confronting CHIRPS dataset and in situ stations in the detection of wet and drought conditions in the Brazilian Midwest. **International Journal of Climatology**, v. 41, n. 9, p. 4478-4493, 2021. <https://doi.org/10.1002/joc.7080>.
- PALHARINI, Rayana Santos Araújo; VILA, Daniel Alejandro. Climatological behavior of precipitating clouds in the northeast region of Brazil. **Advances in Meteorology**, v. 2017, n. 1, p. 5916150, 2017. <https://doi.org/10.1155/2017/5916150>.
- PAREDES-TREJO, Franklin J.; BARBOSA, H. A.; KUMAR, TV Lakshmi. Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil. **Journal of arid environments**, v. 139, p. 26-40, 2017. <https://doi.org/10.1016/j.jaridenv.2016.12.009>.
- PARKER, Wendy S. Reanalyses and observations: What's the difference? **Bulletin of the American Meteorological Society**, v. 97, n. 9, p. 1565-1572, 2016. <https://doi.org/10.1175/bams-d-14-00226.1>
- PEDREIRA JUNIOR, Altemar L. et al. Assessment of remote sensing and re-analysis estimates of regional precipitation over Mato Grosso, Brazil. **Water**, v. 13, n. 3, p. 333, 2021.
- PERRIN, Charles; MICHEL, Claude; ANDRÉASSIAN, Vazken. Improvement of a parsimonious model for streamflow simulation. **Journal of hydrology**, v. 279, n. 1-4, p. 275-289, 2003. [https://doi.org/10.1016/S0022-1694\(03\)00225-7](https://doi.org/10.1016/S0022-1694(03)00225-7).

POLLOCK, Michael Deering et al. Quantifying and mitigating wind-induced undercatch in rainfall measurements. **Water Resources Research**, v. 54, n. 6, p. 3863-3875, 2018. <https://doi.org/10.1029/2017WR022421>.

PRAKASH, Satya. Performance assessment of CHIRPS, MSWEP, SM2RAIN-CCI, and TMPA precipitation products across India. **Journal of hydrology**, v. 571, p. 50-59, 2019. <https://doi.org/10.1016/j.jhydrol.2019.01.036>.

R Development Core Team. R: A Language and Environment for Statistical Computing; **R Foundation for Statistical Computing**: Vienna, Austria. URL <http://www.R-project.org/>, 2015.

RAMAROHETRA, Johanna et al. How satellite rainfall estimate errors may impact rainfed cereal yield simulation in West Africa. **Agricultural and forest meteorology**, v. 180, p. 118-131, 2013. <https://doi.org/10.1016/j.agrformet.2013.05.010>.

RAMOS FILHO, Geraldo Moura et al. Regional-scale evaluation of 14 satellite-based precipitation products in characterising extreme events and delineating rainfall thresholds for flood hazards. **Atmospheric Research**, v. 276, p. 106259, 2022. <https://doi.org/10.1016/j.atmosres.2022.106259>.

REICHLE, Rolf H. et al. Land surface precipitation in MERRA-2. **Journal of Climate**, v. 30, n. 5, p. 1643-1664, 2017. <https://doi.org/10.1175/JCLI-D-16-0570.1>.

REIS, Alberto Assis et al. Hydrological data and modeling to combine and validate precipitation datasets relevant to hydrological applications. **Journal of Hydrology: Regional Studies**, v. 44, p. 101200, 2022. <https://doi.org/10.1016/j.ejrh.2022.101200>.

REN, Wei Wei et al. Improving monthly streamflow prediction in alpine regions: integrating HBV model with Bayesian neural network. **Stochastic Environmental Research and Risk Assessment**, v. 32, p. 3381-3396, 2018. <https://doi.org/10.1007/s00477-018-1553-x>.

RODELL, Matthew et al. The global land data assimilation system. **Bulletin of the American Meteorological society**, v. 85, n. 3, p. 381-394, 2004. <https://doi.org/10.1175/BAMS-85-3-381>.

RODELL, Matthew; LI, Bailing. Changing intensity of hydroclimatic extreme events revealed by GRACE and GRACE-FO. **Nature Water**, v. 1, n. 3, p. 241-248, 2023. <https://doi.org/10.1038/s44221-023-00040-5>.

RODRIGUES, Daniele T. et al. Spatial distribution of the level of return of extreme precipitation events in Northeast Brazil. **International Journal of Climatology**, v. 40, n. 12, p. 5098-5113, 2020. <https://doi.org/10.1002/joc.6507>.

RODRIGUES, Daniele Tôrres et al. Evaluation of the Integrated Multi-SatellitE Retrievals for the Global Precipitation Measurement (IMERG) Product in the São Francisco Basin (Brazil). **Water**, v. 13, n. 19, p. 2714, 2021. <https://doi.org/10.3390/w13192714>.

RODRIGUES, Regina R.; MCPHADEN, Michael J. Why did the 2011–2012 La Niña cause a severe drought in the Brazilian Northeast? **Geophysical Research Letters**, v. 41, n. 3, p. 1012-1018, 2014. <https://doi.org/10.1002/2013GL058703>.

ROZANTE, José Roberto et al. Evaluation of TRMM/GPM blended daily products over Brazil. **Remote Sensing**, v. 10, n. 6, p. 882, 2018. <https://doi.org/10.3390/rs10060882>.

SALTELLI, Andrea. Making best use of model evaluations to compute sensitivity indices. **Computer physics communications**, v. 145, n. 2, p. 280-297, 2002. [https://doi.org/10.1016/S0010-4655\(02\)00280-1](https://doi.org/10.1016/S0010-4655(02)00280-1).

SAMPSON, Christopher C. et al. The impact of uncertain precipitation data on insurance loss estimates using a flood catastrophe model. **Hydrology and Earth System Sciences**, v. 18, n. 6, p. 2305-2324, 2014. <https://doi.org/10.5194/hess-18-2305-2014>.

SANO, Edson E. et al. Cerrado ecoregions: A spatial framework to assess and prioritize Brazilian savanna environmental diversity for conservation. **Journal of environmental management**, v. 232, p. 818-828, 2019. <https://doi.org/10.1016/j.jenvman.2018.11.108>.

SANTANA, Romário O.; DELGADO, Rafael C.; SCHIAVETTI, Alexandre. The past, present and future of vegetation in the Central Atlantic Forest Corridor, Brazil. **Remote Sensing Applications: Society and Environment**, v. 20, p. 100357, 2020. <https://doi.org/10.1016/j.rsase.2020.100357>.

SANTOS, Celso Augusto Guimarães et al. Drought assessment using a TRMM-derived standardized precipitation index for the upper São Francisco River basin, Brazil. **Environmental monitoring and assessment**, v. 189, p. 1-19, 2017. <https://doi.org/10.1007/s10661-017-5948-9>.

SANTOS, Léonard; ANDERSSON, Jafet CM; ARHEIMER, Berit. Evaluation of parameter sensitivity of a rainfall-runoff model over a global catchment set. **Hydrological Sciences Journal**, v. 67, n. 3, p. 342-357, 2022. <https://doi.org/10.1080/02626667.2022.2035388>.

SATGÉ, Frédéric et al. Are gridded precipitation datasets a good option for streamflow simulation across the Juruá river basin, Amazon?. **Journal of Hydrology**, v. 602, p. 126773, 2021. <https://doi.org/10.1016/j.jhydrol.2021.126773>.

SCHLEISS, Marc et al. The accuracy of weather radar in heavy rain: a comparative study for Denmark, the Netherlands, Finland and Sweden. **Hydrology and Earth System Sciences**, v. 24, n. 6, p. 3157-3188, 2020. <https://doi.org/10.5194/hess-24-3157-2020>.

SCHÖNFELDER, L. H., Bakken, T. H., Alfredsen, K., and Adera, A. G.: Application of HYPE in Norway, Assessment of the hydrological model HYPE as a tool to support the implementation of EU Water Framework Directive in Norway, **SINTEF Energy Research**, report no. 2017:00737, Disponível em: <https://sintef.brage.unit.no/sintef-xmlui/handle/11250/2499427> (Acessado em: 22 Feb. de 2022), 2017.

SECOM RS (Secretaria de Comunicação do Estado do Rio Grande do Sul), 2024.
ENCHENTES. Defesa Civil atualiza balanço das enchentes no RS - 18/5, **Secretaria de**

Comunicação, 12h. Disponível em: <<https://estado.rs.gov.br/defesa-civil-atualiza-balanco-das-enchentes-no-rs-18-5-12h/>>. Acesso em 24 Jun. 2024.

SERRAT-CAPDEVILA, A., D. A. García Ramírez, and N. Tayebi (2016), Key Data Needs for Good Water Management, in *Earth Observation for Water Resources Management: Current Use and Future Opportunities for the Water Sector*, edited by L. E. García, D. J. Rodríguez, M. Wijnen and I. Pakulski, p. 267, **The World Bank**, Washington, D.C., <https://doi.org/10.1596/978-1-4648-0475-5>.

SEYYEDI, Hojjat et al. Hydrologic evaluation of satellite and reanalysis precipitation datasets over a mid-latitude basin. **Atmospheric Research**, v. 164, p. 37-48, 2015. <https://doi.org/10.1016/j.atmosres.2015.03.019>.

SHEN, Yan et al. Performance of high-resolution satellite precipitation products over China. **Journal of Geophysical Research: Atmospheres**, v. 115, n. D2, 2010. <https://doi.org/10.1029/2009JD012097>.

SHIN, Mun-Ju et al. Addressing ten questions about conceptual rainfall–runoff models with global sensitivity analyses in R. **Journal of Hydrology**, v. 503, p. 135-152, 2013. <https://doi.org/10.1016/j.jhydrol.2013.08.047>.

SHIN, Mun-Ju; JUNG, Yong. Using a global sensitivity analysis to estimate the appropriate length of calibration period in the presence of high hydrological model uncertainty. **Journal of Hydrology**, v. 607, p. 127546, 2022. <https://doi.org/10.1016/j.jhydrol.2022.127546>.

SILVA, Alexandro Medeiros et al. Modeling the effects of future climate and land-use changes on streamflow in a headwater basin in the Brazilian Caatinga biome. **Geocarto International**, v. 37, n. 26, p. 12436-12465, 2022. <https://doi.org/10.1080/10106049.2022.2068672>.

SIQUEIRA, Vinícius A. et al. Toward continental hydrologic–hydrodynamic modeling in South America. **Hydrology and Earth System Sciences**, v. 22, n. 9, p. 4815-4842, 2018. <https://doi.org/10.5194/hess-22-4815-2018>.

SIT, Muhammed et al. A comprehensive review of deep learning applications in hydrology and water resources. **Water Science and Technology**, v. 82, n. 12, p. 2635-2670, 2020. <https://doi.org/10.2166/wst.2020.369>.

SOBOL, I. M. (1993). Sensitivity estimates for nonlinear mathematical models. *Math. Model. Comput. Exp.*, 1, 407.

SONG, Xiao-meng et al. Hybrid optimization rainfall-runoff simulation based on Xinanjiang model and artificial neural network. **Journal of Hydrologic Engineering**, v. 17, n. 9, p. 1033-1041, 2012.

SOUZA SANTOS, Juliana Aparecida et al. The longest multiannual drought in Northeastern Brazil. **Journal of South American Earth Sciences**, p. 104976, 2024. <https://doi.org/10.1016/j.jsames.2024.104976>.

STEPHENS, Clare M.; MARSHALL, Lucy A.; JOHNSON, F. M. Investigating strategies to improve hydrologic model performance in a changing climate. **Journal of Hydrology**, v. 579, p. 124219, 2019. <https://doi.org/10.1016/j.jhydrol.2019.124219>.

STEPHENS, Clare M. et al. Which Rainfall Errors Can Hydrologic Models Handle? Implications for Using Satellite-Derived Products in Sparsely Gauged Catchments. **Water Resources Research**, v. 58, n. 8, p. e2020WR029331, 2022. <https://doi.org/10.1029/2020WR029331>.

SU, Jianbin et al. How reliable are the satellite-based precipitation estimations in guiding hydrological modelling in South China? **Journal of Hydrology**, v. 602, p. 126705, 2021. [doi:10.1016/j.jhydrol.2021.126705](https://doi.org/10.1016/j.jhydrol.2021.126705).

SU, Jianbin et al. The assessment and comparison of TMPA and IMERG products over the major basins of Mainland China. **Earth and Space Science**, v. 6, n. 12, p. 2461-2479, 2019. <https://doi.org/10.1029/2019EA000977>.

SUN, Qiaohong et al. A review of global precipitation data sets: Data sources, estimation, and intercomparisons. **Reviews of Geophysics**, v. 56, n. 1, p. 79-107, 2018. <https://doi.org/10.1002/2017RG000574>.

SUN, Shanlei et al. Capacity of satellite-based and reanalysis precipitation products in detecting long-term trends across Mainland China. **Remote Sensing**, v. 12, n. 18, p. 2902, 2020. <https://doi.org/10.3390/rs12182902>.

TAMIMINIA, Haifa et al. Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. **ISPRS journal of photogrammetry and remote sensing**, v. 164, p. 152-170, 2020. <https://doi.org/10.1016/j.isprsjprs.2020.04.001>.

TAN, Xuezhi et al. Inconsistent changes in global precipitation seasonality in seven precipitation datasets. **Climate Dynamics**, v. 54, p. 3091-3108, 2020. <https://doi.org/10.1007/s00382-020-05158-w>.

TAREK, Mostafa; BRISSETTE, François P.; ARSENAULT, Richard. Evaluation of the ERA5 reanalysis as a potential reference dataset for hydrological modelling over North America. **Hydrology and Earth System Sciences**, v. 24, n. 5, p. 2527-2544, 2020. <https://doi.org/10.5194/hess-24-2527-2020>.

TAREK, Mostafa; BRISSETTE, François; ARSENAULT, Richard. Uncertainty of gridded precipitation and temperature reference datasets in climate change impact studies. **Hydrology and Earth System Sciences**, v. 25, n. 6, p. 3331-3350, 2021. <https://doi.org/10.5194/hess-25-3331-2021>.

TEGEGNE, Getachew; PARK, Dong Kwan; KIM, Young-Oh. Comparison of hydrological models for the assessment of water resources in a data-scarce region, the Upper Blue Nile River Basin. **Journal of Hydrology: Regional Studies**, v. 14, p. 49-66, 2017. <https://doi.org/10.1016/j.ejrh.2017.10.002>.

TONELLO, Kelly Cristina et al. Rainfall partitioning in the Cerrado and its influence on net rainfall nutrient fluxes. **Agricultural and Forest Meteorology**, v. 303, p. 108372, 2021. <https://doi.org/10.1016/j.agrformet.2021.108372>.

TOTÉ, Carolien et al. Evaluation of satellite rainfall estimates for drought and flood monitoring in Mozambique. **Remote Sensing**, v. 7, n. 2, p. 1758-1776, 2015. <https://doi.org/10.3390/rs70201758>.

TRMM - Tropical Rainfall Measuring Mission. Precipitation Processing System - File Specification for TRMM Products, version 7. NASA, 006. Pp. 983 329, 2017. Disponível em: <<https://arthurhou.pps.eosdis.nasa.gov/Documents/filespec.TRMM.V7.pdf>>. Acessado em: 03 de Jan. 2021.

TURSUN, Arken et al. Reconstruction of missing streamflow series in human-regulated catchments using a data integration LSTM model. **Journal of Hydrology: Regional Studies**, v. 52, p. 101744, 2024. <https://doi.org/10.1016/j.ejrh.2024.101744>.

UN-Water. UN-water analytical brief on water security and the global water agenda. **UN-Water**. https://www.unwater.org/app/uploads/2017/05/analytical_brief_oct2013_web.pdf, 2013.

VAN ROSSUM, G.; DRAKE, F.L. PYTHON 2.6 Reference Manual; **CreateSpace: Scotts Valley**, CA, USA, 2009.

VIEIRA, RM da Silva Pinto et al. Identifying areas susceptible to desertification in the Brazilian northeast. *Solid Earth*, v. 6, n. 1, p. 347-360, 2015. <https://doi.org/10.5194/se-6-347-2015>.

VILLARINI, Gabriele; KRAJEWSKI, Witold F.; SMITH, James A. New paradigm for statistical validation of satellite precipitation estimates: Application to a large sample of the TMPA 0.25° 3-hourly estimates over Oklahoma. **Journal of Geophysical Research: Atmospheres**, v. 114, n. D12, 2009. <https://doi.org/10.1029/2008JD011475>.

WANG, Ning et al. Evaluating satellite-based and reanalysis precipitation datasets with gauge-observed data and hydrological modeling in the Xihe River Basin, China. **Atmospheric Research**, v. 234, p. 104746, 2020a. <https://doi.org/10.1016/j.atmosres.2019.104746>.

WANG, Yuanwei et al. An integration of gauge, satellite, and reanalysis precipitation datasets for the largest river basin of the Tibetan Plateau. **Earth System Science Data**, v. 12, n. 3, p. 1789-1803, 2020b. <https://doi.org/10.5194/essd-12-1789-2020>.

WANG, Jiao et al. Hydrological model adaptability to rainfall inputs of varied quality. **Water Resources Research**, v. 59, n. 2, p. e2022WR032484, 2023. <https://doi.org/10.1029/2022WR032484>.

WANZALA, Maureen A. et al. Assessment of global reanalysis precipitation for hydrological modelling in data-scarce regions: A case study of Kenya. **Journal of Hydrology: Regional Studies**, v. 41, p. 101105, 2022. <https://doi.org/10.1016/j.ejrh.2022.101105>.

WEI, Chong et al. Applicability comparison of various precipitation products of long-term hydrological simulations and their impact on parameter sensitivity. **Journal of Hydrology**, v. 618, p. 129187, 2023. <https://doi.org/10.1016/j.jhydrol.2023.129187>.

WMO: Guide to the Global Observing System., **WMO**. 2010.

WU, Xiaojing et al. Statistical comparison and hydrological utility evaluation of ERA5-Land and IMERG precipitation products on the Tibetan Plateau. **Journal of Hydrology**, v. 620, p. 129384, 2023. <https://doi.org/10.1016/j.jhydrol.2023.129384>.

WU, Yanhong et al. Hydroclimate assessment of gridded precipitation products for the Tibetan Plateau. **Science of the Total Environment**, v. 660, p. 1555-1564, 2019. <https://doi.org/10.1016/j.scitotenv.2019.01.119>.

XAVIER, Alexandre C.; KING, Carey W.; SCANLON, Bridget R. Daily gridded meteorological variables in Brazil (1980-2013). **International Journal of Climatology**, v. 36, n. 6, 2016. <https://doi.org/10.1002/joc.4518>.

XAVIER, Alexandre C. et al. New improved Brazilian daily weather gridded data (1961–2020). **International Journal of Climatology**, v. 42, n. 16, p. 8390-8404, 2022. <https://doi.org/10.1002/joc.7731>.

XU, Jintao et al. Do ERA5 and ERA5-land precipitation estimates outperform satellite-based precipitation products? A comprehensive comparison between state-of-the-art model-based and satellite-based precipitation products over mainland China. **Journal of Hydrology**, v. 605, p. 127353, 2022. <https://doi.org/10.1016/j.jhydrol.2021.127353>.

YANG, Yumeng et al. Applicability of TRMM satellite precipitation in driving hydrological model for identifying flood events: a case study in the Xiangjiang River Basin, China. **Natural Hazards**, v. 87, p. 1489-1505, 2017. <https://doi.org/10.1007/s11069-017-2836-0>.

ZENG, Qiang et al. The effect of rain gauge density and distribution on runoff simulation using a lumped hydrological modelling approach. **Journal of hydrology**, v. 563, p. 106-122, 2018. <https://doi.org/10.1016/j.jhydrol.2018.05.058>.

ZHA, Wenshu et al. Forecasting monthly gas field production based on the CNN-LSTM model. **Energy**, v. 260, p. 124889, 2022. <https://doi.org/10.1016/j.energy.2022.124889>.

ZHAO, Chongxu et al. Statistical and hydrological evaluations of multiple satellite precipitation products in the yellow river source region of china. **Water**, v. 12, n. 11, p. 3082, 2020. <https://doi.org/10.3390/w12113082>.

APÊNDICE A – A COMPREHENSIVE ASSESSMENT OF PRECIPITATION PRODUCTS: TEMPORAL AND SPATIAL ANALYSES OVER TERRESTRIAL BIOMES IN NORTHEASTERN BRAZIL

Remote Sensing Applications: Society and Environment 28 (2022) 100842



Contents lists available at ScienceDirect

Remote Sensing Applications: Society and Environment

journal homepage: www.elsevier.com/locate/rsase



A comprehensive assessment of precipitation products: Temporal and spatial analyses over terrestrial biomes in Northeastern Brazil

João Maria de Andrade^{a,*}, Alfredo Ribeiro Neto^a, Ulisses Alencar Bezerra^b, Ana Carolina Cavalcanti Moraes^a, Suzana Maria Gico Lima Montenegro^a

^a Federal University of Pernambuco, Department of Civil and Environmental Engineering, Recife, Brazil

^b Federal University of Campina Grande, Centre for Natural Resources and Technology, Campina Grande, Brazil

ARTICLE INFO

Keywords:

TRMM
CHIRPS
Google earth engine
IMERG
ERA5-Land

ABSTRACT

Precise rainfall estimations at spatio-temporal resolution are vital for numerous applications, including agricultural monitoring, hydrometeorology, and water resources management. Northeast Brazil (NEB) is vulnerable to extreme interannual climate variability and precipitation is closely linked to the livelihoods of its citizens and the regional health of the economy. Satellite rain data is an alternative source of information for regions such as NEB. Thus, this study aimed to evaluate the performance of monthly rainfall estimations derived of latest versions from five precipitation products: (i) CHIRPS, (ii) ERA5-Land, (iii) TerraClimate, (iv) TRMM, and (v) IMERG in the NEB and comparing them to the observed precipitation for the period 2001–2019. The results showed that the satellite-based products were more regularly correlated with the observed precipitation than the model-based products. CHIRPS, IMERG and, TRMM showed an average Pearson's correlation coefficient (r) value above 0.93. All products tended to present lower relative error in the rainy months; TerraClimate gave the highest average value of root-mean-square error (RMSE) for NEB (41.61 mm/month). The best global performance was observed in the Amazon biome ($r \sim 0.90$), and the poorest in the Atlantic Forest biome, which tended to underestimate the precipitation. In spite of the results in the Atlantic Forest, this study demonstrated that products of precipitation can be a useful complement to rainfall data for the NEB. The comprehensive assessment of precipitation products reported here will serve as a reference for managers and researchers to select the ideal product for its intended application and associated uncertainties.

1. Introduction

The Northeast Brazil (NEB) region covers an area of approximately 1.5 million km², corresponding to 20% of the Brazilian territory (Martins et al., 2019). The region is vulnerable to climatic extremes and will be affected by rainfall deficits and increases in aridity over this century (Vieira et al., 2015). Rainfall variability, soil degradation, and desertification are some of the factors that could make this region one of the most vulnerable to climate change globally (Marengo et al., 2017). The soils in NEB are typically shallow, over crystalline rock (Silva et al., 2022), retaining water only for a short period after the rainy season. Precipitation in the NEB is closely linked to the livelihoods of its citizens and the health of the economy of the region, as agricultural production is exposed to high rainfall variability, which affects most farmers (Nelson and Finan, 2009). About 80% of the food consumed in the region is provided by smallholder farmers who use rainfed agriculture, which depends on rainfall and water stored in the soil (IBGE, 2019; ANA –

* Corresponding author.

E-mail address: joao.jma@ufpe.br (J.M. de Andrade).

<https://doi.org/10.1016/j.rsase.2022.100842>

Received 10 June 2022; Received in revised form 19 August 2022; Accepted 20 September 2022

Available online 24 September 2022

2352-9385/© 2022 Elsevier B.V. All rights reserved.

Agência Nacional de Águas, 2020). Precipitation is one of the most important atmospheric variables in global water and energy cycles. A long and reliable temporal record of precipitation is crucial for different applications, including hydrological modeling, agricultural monitoring, hydrometeorology, water resources management, flood and drought monitoring, and climatological applications (Baethgen and Goddard, 2013; Toté et al., 2015). Observations from terrestrial rain gauges provide accurate local precipitation measurements. However, the low density of rain gauge, the high proportion of missing data and short-length records make reliable rainfall analysis unfeasible, which is more evident in some areas of the NEB (Rodrigues et al., 2020). In addition, the limited spatial representativeness and non-homogeneous distribution of rainfall stations restrict their applicability on a global scale (Kidd et al., 2017).

Global and continental satellite-based and model-based precipitation products offer a unique opportunity to study the high spatiotemporal variability of precipitation on a worldwide scale for application in hydrological and climatic studies and monitoring (Dembélé and Zwart, 2016), identification of meteorological droughts (Santos et al., 2017; Brito et al., 2021) and flood events (Toté et al., 2015). However, these estimations have several limitations because none of the satellite sensors directly detect rain; they suffer from errors and uncertainties originating from various sources, including sensor calibration, algorithmic approximations, and sampling (Ramarohetra et al., 2013). In recent decades, efforts have been made by various global institutions and organizations to release satellite-based precipitation data with various resolutions and spatiotemporal coverages (Xu et al., 2022). The Tropical Rainfall Measuring Mission (TRMM), launched in 1997, has been considered preeminent in precipitation measurements with high-quality data for applications for nearly 20 years (Huffman et al., 2007; Kidd and Huffman, 2011). As the successor to TRMM, the Global Precipitation Measurement (GPM) was released in 2014, and the Integrated Multi-satellite Retrievals for GPM (IMERG) is a unified algorithm that provides precipitation estimations by combining data from all passive microwave instruments in the GPM constellation, providing improved estimations of light and frozen precipitation, and more precise spatiotemporal resolutions (Kirschbaum et al., 2017; Huffman et al., 2019). However, TRMM-based multisatellite precipitation products are limited in use in climatological applications, with data only available from 1998 onward. Therefore, to fill the gap in the availability of high-resolution multisatellite precipitation products before 1998, a new climate database of terrestrial precipitation, the Climate Hazards Group InfraRed Precipitation with Station data (CHIRPS), was developed (Funk et al., 2015). CHIRPS encompasses three different types of information: global climatologies, satellite estimations, and in situ observations; it belongs to the “satellite-gauge” category (Duan et al., 2016).

Another alternative approach to obtain global precipitation estimations is that of reanalysis data based on meteorological and numerical models that use data assimilation techniques (Xu et al., 2022). ERA5-Land is a fifth-generation climate reanalysis dataset produced by the European Center for Medium-Term Weather Forecasts (ECMWF) that is based on ERA5 with thermodynamic orographic temperature adjustments (Muñoz Sabater, 2019). TerraClimate is a dataset produced by combining spatial climatology from WorldClim with time-varying information from the Climate Research Unit (CRU Ts4.0) (Abatzoglou et al., 2018).

Many studies have been conducted to assess precipitation products on global, continental, and regional scales (Duan et al., 2016; Prakash, 2019; Tan et al., 2020; Dubey et al., 2021; Xu et al., 2022). Several evaluation studies have been performed in Brazil. For example, Oliveira et al. (2018) assessed the characteristics and uncertainty of IMERG over the Central Amazon Region. Gadelha et al. (2019) evaluated the IMERG over Brazil at the grid box level at various time and space scales for the period between January–December 2016. Freitas et al. (2020) evaluated the capability of IMERG in defining sub-daily rainfall events and their properties for a period of three years (2015–2017). Melo et al. (2015) evaluated Brazil's TRMM 3B42V6 and V7 rainfall performance estimations. Mu et al. (2021) compared the accuracy of three satellite-based precipitation products from 1981 to 2019 over the state of Rondônia in the Brazilian Amazon, and Paredes-Trejo et al. (2017) validated the CHIRPS precipitation product on a monthly scale for 1981–2013 in NEB. Brito et al. (2022) evaluated two precipitation products to estimate rainfall and erosivity, including CHIRPS, in a Brazilian semiarid basin. Brito et al. (2021) analyzed meteorological drought with precipitation products (including CHIRPS), in a Brazilian semiarid basin. Table 1 provides a tabular review of the literature that shows some relevant studies assessing different precipitation products at continental and regional scales. The TRMM, IMERG, CHIRPS, TerraClimate, and ERA5-Land precipitation prod-

Table 1

Summary of relevant studies evaluating different precipitation products at continental and regional scales in relation to the proposed study.

Study	Precipitation Products	Timescale	Location/study area	Study period	Analysis approach
Duan et al. (2016)	TRMM, CMORPH_RAW, CMORPH_CRT, CMORPH_BLD, PCDR, PGF, CHIRPS, GSMaP_MVK	Daily, monthly, annual	Adige Basin-Italy/ 0.012 M km ²	2000–2010	Grid box
Prakash (2019)	CHIRPS, MSWEP, SM2RAIN-CCI, TRMM	Monthly	India/3.3 M km ²	1998–2015	Grid box
Xu et al. (2022)	IMERG, GSMaP, ERA5, ERA5-Land	Hour, daily, annual	China/9.3 M km ²	2016–2019	Point cell and grid box
Gadelha et al. (2019)	IMERG	Daily, monthly, annual	Brazil/8.5 M km ²	2016	Grid box
Melo et al. (2015)	TRMM	Daily, monthly	Brazil/8.5 M km ²	1998–2011	Grid box
Mu et al. (2021)	CHIRP, CHIRPS	Monthly	Rondônia-Brazil/ 0.24 M km ²	1981–2019	Point-cell
Paredes-Trejo et al. (2017)	CHIRPS	Monthly	Northeast Brazil/ 1.56 M km ²	1981–2013	Point-cell
This study	CHIRPS, IMERG, TRMM, ERA5 Land, TerraClimate	Monthly, annual	Northeast Brazil/ 1.56 M km ²	2001–2019	Grid box

ucts are currently available on the Google Earth Engine (GEE). GEE is a cloud-based geospatial processing platform that was launched by Google in 2010, which compiles trillions of scientific measurements (including meteorological observations such as precipitation, temperature, and wind speed) (Gorelick et al., 2017). The main advantages of GEE are its remarkable processing capacity and large-scale application (Tamiminia et al., 2020).

Given the various available precipitation products, it is essential to compare each with the available field observations for their wider use and applicability (Dubey et al., 2021). This can be especially beneficial for some terrestrial data-poor areas in NEB and other regions of South America and Africa (Sampson et al., 2014; Xavier et al., 2016; Kidd et al., 2017; Brocca et al., 2020). The NEB is an ideal region for assessing the accuracy of precipitation products, considering its spatial coverage and various hydro-geo-climatological characteristics with three climate zones (tropical, semiarid, and humid subtropical) and four biomes (Amazon, Cerrado, Caatinga, and Atlantic Forest). Furthermore, a comprehensive evaluation of these precipitation products at distinct spatial and temporal scales is essential for their practical application and serves as a reference for managers and researchers to select the ideal product for its intended application and its associated uncertainties. The comprehensive assessment of precipitation products reported here will serve as a reference for managers and researchers to select the ideal product for its intended application and associated uncertainties. Considering the gaps in previous studies in Brazil, to our knowledge, this is the first study that evaluates five precipitation products at different spatial and seasonal scales over nineteen years in different NEB biomes. This study provides insights into the performance of precipitation products in the NEB. Therefore, the main questions addressed in this study are as follows: (a) Do precipitation products perform similarly? (b) Is the data quality of the precipitation products similar in different seasonal periods? (c) Does the data performance of the precipitation products vary spatially? (d) Does the data quality of precipitation products vary at different time scales? The results obtained will inform users of the strengths and weaknesses of these products and help to select the appropriate dataset based on their respective applications.

2. Data and methods

2.1. Study area

The NEB is located at the eastern end of South America, between 1° and 18° S and 35° and 47° W (Fig. 1). The region has marked interannual rainfall variability, with some years being extremely dry and others extremely rainy. In addition, rainfall in the region varies between 250 and 2000 mm (Martins et al., 2019; Costa et al., 2020) (Fig. 1B). In Fig. 1A, it is possible to see the three climate zones that comprise the region: tropical (Zone A), semiarid (Zone B), and humid subtropical (Zone C) (Alvares et al., 2013). It is also possible to observe that the rainy period occurs in different months in three sub-regions: January to June in Region 1 (R1), March to August in Region 2 (R2), and November to April in Region 3 (R3) (adapted from Lucena et al., 2011; Cunha et al., 2015; Costa et al., 2020).

Four main biomes are found in the NEB: the Amazon, Cerrado, Caatinga, and Atlantic Forest (Fig. 1B). The Amazon biome consists of a dense tropical rainforest with an average annual rainfall of 2300 mm and a short dry season (Mu et al., 2021). The Cerrado biome is characterized by forests and savannas with well-defined dry and rainy seasons with annual precipitation ranges from 600 mm to




Fig. 1. Location of NEB. A) Köppen's climate classification for NEB (according to Alvares et al., 2013; A, B, and C stand the climate zones Tropical, Semiarid, and Humid Subtropical, respectively) and R1, R2 and R3 are subregions defined by the rainy period (yellow outlines; adapted from Lucena et al., 2011; Costa et al., 2020; Cunha et al., 2015), B) location of the biomes present in the NEB and spatial distributions of the annual mean rainfall (mm) between 2001 and 2019 (Xavier et al., 2022). (For interpretation of the references to colour in this figure legend, the reader is referred to the Web version of this article.)

2000 mm (Sano et al., 2019; Tonello et al., 2021). The Atlantic Forest is characterized by the coverage of humid forests in coastal areas and semi-deciduous forests in continental areas with well-defined rainy and dry seasons with annual rainfall (approximately from 800 to 4000 mm) (Duarte et al., 2014; Santana et al., 2020). Finally, the Caatinga biome, the largest biome in the NEB, is a semi-arid region with herbaceous and arboreal vegetation and presents the lowest values of annual precipitation with a severe dry season, where approximately 70% of the annual precipitation occurs from February to April (Almagro et al., 2020; Andrade et al., 2021), with precipitation being a limiting factor of phenological dynamics vegetation (Medeiros et al., 2022). The precipitation in this Caatinga biome is extremely irregular, with annual rainfall from 240 to 1500 mm (Beuchle et al., 2015). The strength of NEB precipitation variability depends on the location and magnitude of the Sea Surface Temperature (SST) anomalies in the Pacific and Atlantic. NEB precipitation anomalies are linked to some modes of natural variability, including El Niño/Oscillation (ENSO), Pacific Decadal Oscillation (PDO), and Atlantic Multidecadal Oscillation (AMO) (Rodrigues and McPhaden, 2014; Barbosa and Kumar, 2016); therefore, changes in the precipitation regime in the NEB are likely caused by variations in these modes.

2.2. Precipitation data sets

2.2.1. Observed precipitation

The grid precipitation product derived from rain gauges with 0.1° spatial resolution for Brazil (Xavier et al., 2022) was used as the reference dataset i.e. observed precipitation, to compare the precipitation products. This daily precipitation dataset used observed precipitation data derived from approximately 11,473 rain gauges from the National Water and Sanitation Agency (ANA), and National Institute of Meteorology (INMET) from January 1961 to July 2020. The Angular Distance Weighting (ADW) method was used to generate the gridded observed precipitation data. The observed precipitation is available at <https://sites.google.com/site/alexandrecandidoxavierufes/brazilian-daily-weather-gridded-data?authuser=0>.

2.2.2. Precipitation products

Five precipitation products from the CHIRPS, ERA5-Land, TerraClimate, IMERG, and TRMM for 2001–2019, based on the common availability period of each precipitation dataset, were used in this study (Table 2). Data from satellite and models precipitation products were obtained using the GEE platform (Gorelick et al., 2017).

CHIRPS is a near-global (50° S–50° N) long-term precipitation dataset developed by the United States Geological Survey (USGS) and the Climate Hazards Group (CHG) for analyzing trends and monitoring seasonal droughts (Funk et al., 2015). CHIRPS incorporates 0.05° resolution satellite imagery with in situ station data to create a gridded rainfall time series for these purposes (Funk et al., 2015). The main datasets used for the construction of the CHIRPS product include (i) data from rainfall stations from various sources, (ii) monthly rainfall climatology (CHPclim), which uses rainfall stations collected from the FAO and GHCN; (iii) cold cloud duration (CCD) information based on archived thermal infrared (TIR) data from the CPC and NOAA National Climate Data Center (NCDC), which considers the duration of the cold cloud that is the time interval in which a temperature pixel is below a certain threshold, and (iv) Version 7 TRMM 3B42 data (Duan et al., 2016; Dembélé and Zwart, 2016). This dataset has been used in numerous scientific studies (Luo et al., 2019; Hurtado et al., 2021; Mokhtari et al., 2022).

ERA5-Land is a reanalysis dataset that provides a consistent view of the evolution of soil variables over several decades at an improved resolution compared to that of ERA5. ERA5-Land was produced from the ECMWF ERA5 climate reanalysis terrestrial component with a spatial resolution of 0.1° (Muñoz Sabater, 2019). Reanalysis combines model data from worldwide observations into a globally complete and consistent dataset using the laws of physics (Muñoz Sabater, 2019). ERA5-Land uses as the input ERA5 atmospheric variables. The inlet air temperature, air humidity, and pressure used with ERA5-Land were corrected to account for the altitude difference and the higher resolution grid of ERA5-Land (Muñoz Sabater, 2019). The fine spatiotemporal resolution of ERA5-Land makes this dataset useful for all types of ground surface applications (Xu et al., 2022; Longo-Minnolo et al., 2022; Nazeer et al., 2022).

TerraClimate is a monthly climate dataset and climate water balance for global land surfaces at 0.04° spatial resolution, which is produced by combining coarse-resolution time-varying data from the Climate Research Unit (CRU Ts4.0) and 55-year Japanese Reanalysis (JRA55) (Abatzoglou et al., 2018). This dataset uses weather-assisted interpolation, combining high spatial resolution climatological normals from the WorldClim dataset with a coarser time resolution. TerraClimate produces a monthly dataset of precipitation, maximum and minimum temperatures, wind speed, vapor pressure, and solar radiation (Abatzoglou et al., 2018). Many studies have used this dataset for various applications (Abdi, 2019; Ahamed et al., 2022).

The TRMM was launched by the US National Aeronautics and Space Administration and the Japan Aerospace Exploration Agency to monitor tropical and subtropical precipitation (Arshad et al., 2021). TRMM merges microwave data from multiple satellites. The 3B43 algorithm runs once a month to produce the single best-estimate precipitation rate and precipitation error estimate field, com-

Table 2

Summary of satellite-based products that provide daily and monthly data on a global scale on the GEE.

Product	Version	Spatial Resolution	Temporal Resolution	Period
CHIRPS	CHIRPS v.2	0.05°	Daily	1981 – Present
ERA5-Land	ERA5-LAND v.5	0.1°	Daily/Monthly	1981 – Present
TRMM	TRMM 3B43 v.7	0.25°	Sub-daily/ Daily/Monthly	1998 – 2019
IMERG	IMERG v.6	0.1°	Sub-daily/ Daily/Monthly	2000 – Present
TerraClimate	TerraClimate v.2	0.04°	Monthly	1958 – Present

binning high-quality estimation with monthly cumulative global precipitation from the Global Precipitation Climatology Centre (GPCC) (TRMM - TROPICAL RAINFALL MEASURING MISSION, 2017). The TRMM mission ended in April 2015.

The Global Precipitation Measurement (GPM)-IMERG, provides next-generation observations of rain and snow every 3 h with a spatial resolution of 0.1° . IMERG is the unified algorithm that provides precipitation estimations by combining data from all passive microwave (PM) instruments in the GPM constellation. Sensors (PM) on polar-orbiting satellites can penetrate clouds to explore their properties and identify scattering precipitation particles due to large ice particles (Dembélé and Zwart, 2016; Paredes-Trejo et al., 2017). In general, PM is used for estimating the amount of rain because of the increase in the direct physical relationship between the sensor signal and precipitation (Dembélé and Zwart, 2016). The IMERG algorithm is intended to calibrate, merge, and interpolate all satellite PM estimations along with microwave-calibrated infrared (IR) satellite estimations, precipitation meter analyses, and other precipitation estimators with fine time and spatial resolution scales for the TRMM and GPM areas across the globe (Huffman et al., 2019).

2.3. Validation statistics

The performance evaluation was conducted for the common overlapping periods of the different sources from 2001 to 2019, totalling 19 years of analysis to NEB. The satellite's precipitation and reanalysis products have different spatial resolutions ranging from 0.04° to 0.25° , so they were resampled to the observed spatial resolution of precipitation on a grid (0.1°). In addition, as they are in different temporal resolutions (daily and monthly), the products with daily rainfall data were accumulated to produce monthly information and standardize the temporal resolution for the monthly scale.

For a detailed evaluation of precipitation products with observed precipitation data, and considering that a single metric provides only a projection of a certain aspect of the characteristic errors (Ferreira et al., 2020), four continuous statistical metrics, i.e. percent bias (PBIAS), Pearson's correlation coefficient (r), root-mean-square error (RMSE) and relative root mean square error (RRMSE), were calculated for each grid point (12854 in NEB) for the study period. PBIAS measures the average trend of the estimated values, which may be higher or lower than those observed, with an optimal value of 0. The Pearson's r coefficient measures the strength of the linear relationship between estimates and observations, ranging from -1 to 1 , with a perfect score of 1 . The RMSE provides information on the error estimation and the average magnitude of the error estimations [mm.month $^{-1}$], and the RRMSE is calculated by dividing RMSE with average observation data. Both have with ideal values close to zero. PBIAS measures the average trend of the estimated values, which may be higher or lower than those observed, with an optimal value of 0 . The equations, value ranges, and perfect values of the statistical metrics mentioned are listed in Table 3.

2.4. Spatial and seasonal analysis

Using the period between 2001 and 2019 from observed precipitation data and precipitation products, we assessed spatial and biome-wide patterns using the metrics described in section 2.3. For this, we performed the analyses on the following scales: (i) monthly: it evaluates the products for each month of the time series on a monthly scale, (ii) seasonal: it evaluates the performance of the products by month of the year (January, February, March, April, May, June, July, August, September, October, November and December) and (iii) annual: it evaluates the total annual precipitation for each grid point over NEB.

3. Results

3.1. Spatial analysis at monthly scale

Fig. 2 shows the spatial distributions of the statistical metrics of monthly rainfall over 19 years of NEB data derived from the five precipitation products and precipitation observed and the mean and standard deviation (sd) of PBIAS, r , RMSE, and RRMSE values of the entire NEB are also provided for each precipitation product (Table 4), the values of the statistical metrics were rounded to the nearest 2-decimal digits. IMERG, CHIRPS and TRMM presented the highest values of r (0.93), whereas TerraClimate and ERA5-Land revealed the lowest value (0.89). Overall, the ERA5-Land underestimated precipitation with a PBIAS value of -2.61% , while CHIRPS, IMERG, TRMM and TerraClimate overestimated precipitation with a PBIAS value ranging from 3.53% to 13.35% . Although ERA5-Land presents the best mean PBIAS value (-2.61), it is the one that offers the highest sd value ($+17.4$), indicating greater variability in the recorded values; this can be observed in Fig. 2, which shows the contrast between the eastern region of the NEB that tends to underestimate the precipitation and the western portion that presents a greater tendency

Table 3

List of statistical metrics for evaluating precipitation products in this study.

Metrics names	Equations	Value Range	Perfect Values
Percent bias (PBIAS)	$PBIAS = \frac{\sum_{i=1}^n (Si - Gi) - 100}{\sum_{i=1}^n Gi}$	$] -\infty, \infty[$	0
Pearson's correlation coefficient (r)	$r = \frac{\sum_{i=1}^n (Si - S)(Gi - G)}{\sqrt{\sum_{i=1}^n (Si - S)^2 \cdot \sum_{i=1}^n (Gi - G)^2}}$	$[-1, 1]$	1
Relative root mean square error (RRMSE)	$RMSE = \left(\frac{\sum_{i=1}^n (Si - Gi)^2}{n} \right)^{0.5}$	$[0, +\infty[$	0
Relative root mean square error (RRMSE)	$RRMSE = \frac{RMSE - 100}{G}$	$[0, +\infty[$	0

Note: Si is estimated precipitation from the evaluated products, Gi is the observed precipitation, S and G are their respective averages, and n is the number of observations.




Fig. 2. Spatial distributions of A) PBIAS, B) r , C) RMSE, and D) RRMSE of monthly rainfall of CHIRPS, ERA5-Land, IMERG, TerraClimate, and TRMM compared to observed precipitation for the period 2001–2019 in NEB. The mean values of PBIAS, r , RMSE, and RRMSE are also provided for each precipitation product.

to overestimate. The RMSE value varied from 29.63 mm/month (CHIRPS) to 41.61 mm/month (TerraClimate); the highest values were recorded on the coast and northwest portion of the NEB. The RRMSE value varied from 42.28% to 58.16%, and the highest values were recorded in the central portion NEB. The satellite-based products (CHIRPS, IMERG, and TRMM) performed similarly and generally outperform model-based products (TerraClimate and ERA5-Land). Therefore, three of these products (CHIRPS, IMERG and, TRMM) can reasonably be considered the main products for estimating total monthly rainfall.

3.2. Seasonal analysis

To evaluate the performance of rainfall estimations derived from these precipitation products in the seasonal context, the values of the numerical metrics by month in the period 2001–2019 on NEB are illustrated in Fig. 3. The lowest RMSE values were recorded

Table 4
Summary mean and standard deviation (sd) of descriptive statistics of monthly rainfall at NEB. The best values are shown in bold.

Product	Validation statistics			
	PBIAS(%)	r	RMSE (mm/month)	RRMSE(%)
CHIRPS	3.53 + 10.60	0.93 + 0.05	29.63 + 9.17	42.28 + 12.80
ERA5-Land	-2.61 + 17.40	0.89 + 0.05	38.82 + 12.0	54.84 + 15.60
IMERG	13.4 + 15.4	0.94 + 0.03	31.69 + 8.49	45.79 + 15.70
TerraClimate	3.00 + 11.90	0.86 + 0.07	41.61 + 15.6	58.16 + 15.80
TRMM	10.85 + 13.90	0.93 + 0.03	32.72 + 9.37	46.67 + 13.70




Fig. 3. Boxplot graphs of performance metrics A) PBIAS, B) r, C) RMSE, and D) RRMSE for each month from 2001 to 2019 for the precipitation products (CHIRPS, ERA5-Land, IMERG, TerraClimate, and TRMM) on NEB.

from July to October, with values greater than 25 mm/month (Fig. 3), however in this period the highest values of (RRMSE) were recorded. In addition, during this period, a tendency of underestimation was evidenced in the precipitation values estimated by the satellites with PBIAS values lower than zero. From February to May, there was an increase in the RMSE value (> 40 mm/month), and PBIAS values approximated 0. In general, the r values were high, with values above 0.7 for most months. In addition, January was clearly the month with the highest value, while the r values for June, July, and August showed good performance (Fig. 3).

Fig. 4 shows the statistical metrics of monthly rainfall for the NEB subregions defined by the rainy period (Fig. 1A). TRMM and IMERG show an overestimation trend for regions R1 and R3, in contrast to the other products (CHIRPS, ERA5-Land, and TerraClimate), which revealed underestimations. The PBIAS values ranged from -51.75% to 87.4% . Region R2, located on the NEB coast, presents an underestimation trend for all products for most of the year. The dry seasons of each region record the lowest RMSE values (< 25 mm/month) and RRMSE values $> 50\%$, while RMSE values above 50 mm/month are recorded in the rainy season and RRMSE values $< 55\%$. IMERG, TRMM, and CHIRPS record the highest r values for the three regions, and as indicated in Fig. 4, the highest r values are recorded in January for all regions (R1, R2, and R3).

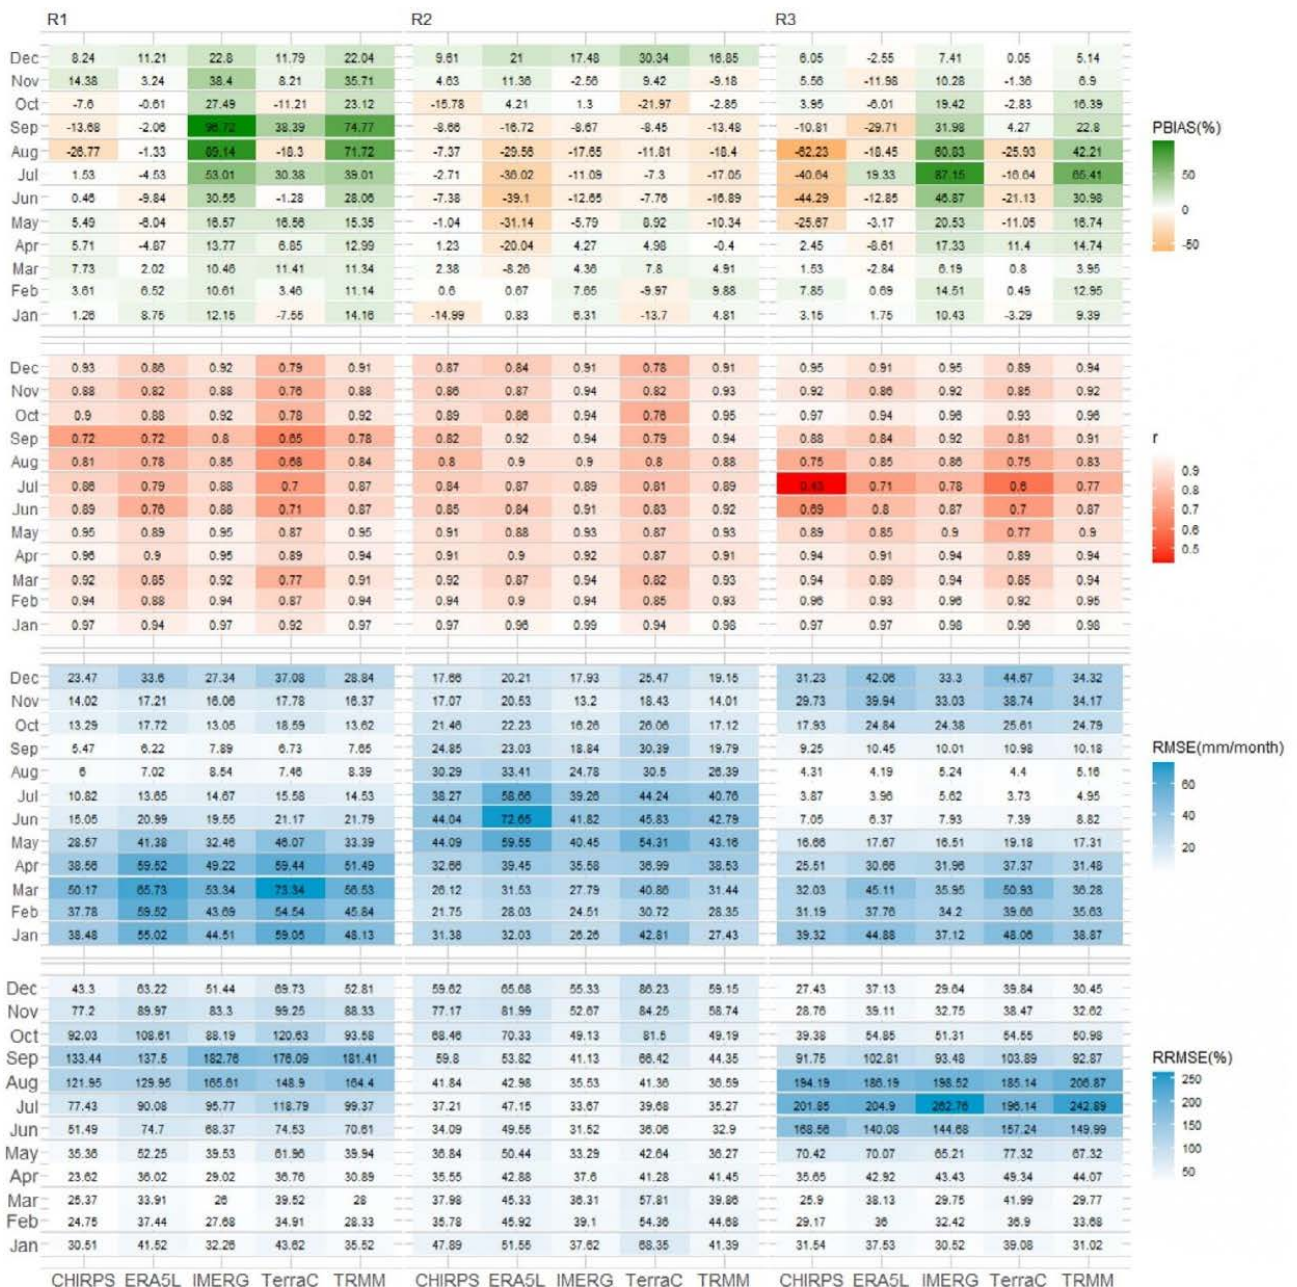


Fig. 4. Median values of performance metrics (PBIAS, r , RMSE and RRMSE) by month of the year from 2001 to 2019 for the precipitation products (CHIRPS, TRMM, IMERG, ERA5-Land, and TerraClimate) for three subregions defined by the rainy period: (R1) January to June; (R2) March to August; and (R3) November to April (adapted from Lucena et al., 2011; Costa et al., 2020; Cunha et al., 2015). TERRAC: TerraClimate, ERA5L: ERA5-Land.

3.3. Performance per biome at monthly scale

In this section, we present the performance metric results for each biome in NEB. For comparison, the performance metrics were assessed using boxplots (Fig. 5). Overall, satellite products tend to underestimate precipitation for the Atlantic Forest biome, located on the east coast of the NEB, with median PBIAS values ranging from approximately -8% (CHIRPS) to -25% (ERA5-Land). For the Caatinga biome, the median value of PBIAS ranged from 12% to -12% . The highest values of RMSE occurred in the Amazon and Atlantic Forest, whereas the Cerrado and Caatinga biomes had the lowest values. The highest values of RRMSE occurred for Caatinga and Atlantic Forest. The Amazon biome presented the highest r value, with median values from 0.87 to 0.95 , and the rain gauges located in the Atlantic Forest presented median values from 0.82 to 0.90 . In contrast, the Caatinga and Cerrado biomes showed values above 0.80 from most of the grid points.

To provide further information on the behaviour of the satellite products, a comparison was performed between the time series of monthly mean precipitation of the observed precipitation and the CHIRPS, TRMM, IMERG, ERA5-Land, and TerraClimate products over each biome of the NEB (Amazon, Caatinga, Cerrado, and Atlantic Forest) (Fig. 6). In general, the products could adequately capture the variability of precipitation in the NEB and present a good correspondence with the data from the rain gauges. However, the tendency of TerraClimate to overestimate precipitation in the Amazon biome is shown, especially during the rainy season and ERA5-Land to underestimate precipitation in the Atlantic Forest biome.

3.4. Evaluation at annual scale

Monthly total precipitation data were further accumulated for annual total precipitation. Spatial distributions of the statistical metrics of annual precipitation data for all precipitation products are plotted in Fig. 7. Overall, on this time scale, there was a reduc-




Fig. 5. Boxplot of A) PBIAS, B) r , C) RMSE and D) RRMSE metrics from the CHIRPS, TRMM, IMERG, ERA5-Land, and TerraClimate products for each biome of the NEB (Amazon, Caatinga, Cerrado, and Atlantic Forest) for monthly precipitation.




Fig. 6. Mean precipitation monthly derived from observed precipitation and the CHIRPS, TRMM, IMERG, ERA5 Land, and TerraClimate products over each biome of the NEB A) Amazon, B) Atlantic Forest, C) Caatinga, and D) Cerrado for the period of 2001–2019.

tion in r values for all products with values less than 0.84. About PBIAS, the metrics did not change significantly. As expected, the RMSE values increased at the annual scale; however, a reduction in the RRMSE values was registered compared to the monthly scale ($< 22\%$). As in the monthly scale, CHIRPS, IMERG, and TRMM presented the best performance metrics.

We presented the performance metric results for each biome in NEB for annual precipitation. For comparison, the performance metrics were assessed using boxplots (Fig. 8). In general, the Atlantic Forest biome presented the worst performance metrics. The r values were lower in all biomes compared to the monthly scale. The highest relative errors (RRMSE) were registered for the Atlantic Forest and Caatinga biomes.

Fig. 9 shows the spatial pattern of mean annual precipitation over the NEB during 2001–2019 from observed precipitation data and the five products evaluated at the common spatial resolution of 0.1° . From the interpolated rainfall data, the mean annual precipitation ranged from 350 mm to 2300 mm/year. As expected, the highest values were recorded for the Amazon biome and the lowest for Caatinga. Overall, all the products captured the precipitation distribution patterns in the NEB. However, in some regions of the NEB, it is evident the difficulty of the products to adequately reproduce the magnitude of precipitation with a tendency to overestimate and underestimate what is occurring in different locations. For instance, the eastern coast of the NEB presents a tendency to underestimate the precipitation and some areas of the Caatinga with a tendency to overestimate the precipitation.

4. Discussion

The present work contributes to increasing the knowledge of the use of precipitation products derived from satellites in NEB at spatial and seasonal scales. Overall, IMERG, TRMM, and CHIRPS exhibited the best performance metrics. A possible explanation for why CHIRPS and IMERG outperform ERA5-Land and TerraClimate is that these satellite precipitation products undergo a ground calibration (Lopez, 2011; Hersbach et al., 2020; Abatzoglou et al., 2018; Xu et al., 2022). CHIRPS uses TRMM data to calibrate global cold cloud duration rainfall estimates, which may explain the similar performances of these three products (CHIRPS, IMERG and TRMM) (Funk et al., 2015; Katsanos et al., 2016). This is generally consistent with previous studies (Melo et al., 2015; Paredes-Trejo et al., 2017; Gadelha et al., 2019; Pedreira et al., 2021) in which TRMM 3B42, IMERG, and CHIRPS were well adapted to represent the variability of precipitation, except in the region closest to the east coast (Atlantic Forest biome), where the product had the poorest metrics. This can be explained by the presence of warm clouds common on the east coast of the NEB that contribute to a greater deficiency in satellite rainfall estimations (Melo et al., 2015; Gadelha et al., 2019; Freitas et al., 2020; Pedreira et al., 2021). Rozante et al.




Fig. 7. Spatial distributions of A) PBIAS, B) r , C) RMSE, and D) RRMSE of the annual rainfall of CHIRPS, ERA5 Land, IMERG, TerraClimate, and TRMM compared to observed precipitation for the period 2001–2019 in NEB. The mean values of PBIAS, r , RMSE, and RRMSE to all are also provided for each precipitation product.

(2018) detected a strong underestimation for the Brazilian coastal region by analyzing the IMERG and TRMM products. [Rodrigues et al. \(2021\)](#) indicated that a possible explanation for this underestimation on the east coast of NEB is the type of climate system driven by the intertropical convergence zone with the presence of warm clouds. Warm clouds have little vertical development and low ice content, making it difficult to estimate precipitation using satellites ([Hobouchian et al., 2017](#)). Approximately 50% of the precipitating clouds in NEB do not contain ice in their structure, and passive microwave sensors cannot efficiently detect these; however, active microwave sensors can penetrate clouds and are more effective ([Palharini and Vila, 2017](#)).

In addition, the differences between the evaluated precipitation products and observed precipitation can be attributed to several factors, including errors in satellite sampling, algorithms for estimating precipitation from individual platforms, errors in algorithms for mixing individual estimations, and measurements from rainfall stations ([Shen et al., 2010](#)). In general, the amount of current pre-




Fig. 8. Boxplot of A) PBIAS, B) r , C) RMSE, and D) RRMSE metrics from the CHIRPS, ERA5-Land, IMERG, TerraClimate, and TRMM products for each biome of the NEB (Amazon, Caatinga, Cerrado, and Atlantic Forest) for annual precipitation.

precipitation that reaches the ground is generally higher than that measured in rain gauges (Dahri et al., 2018); this is explained due to measurement errors affecting rain gauges, such as exposure to high temperatures and prevailing winds and the topography and vegetation around the rain gauge. Rain gauges can underestimate precipitation by up to 25%–30% in heavy rain and windy conditions (Schleiss et al., 2020; Pollock et al., 2018). Under-capture of wind-induced and high-temperature precipitation over the NEB may be the dominant source of errors in rain gauge observations. One of the common sources of errors and uncertainties in satellite precipitation products is the a priori databases of cloud and precipitation profiles; in the absence of radar observations over the continent, those priori databases to retrieve passive microwave-based satellite precipitation estimates are not robust enough (Xu et al., 2022). Evaporation of hydrometeors from the cloud or subcloud base is also an aspect that is ignored by satellite precipitation products (Dubey et al., 2021). In addition, the ground surface background emissivities that depend on factors such as climate, vegetation and terrain play the most critical role in the uncertainty of satellite precipitation estimation (Maggioni et al., 2014).

Precipitation products captured the seasonality of the precipitation for the different NEB biomes. The five products tended to have the highest errors (RMSE) during the wettest months (December–April), which can be explained by the coincidence of the rainy season in the three subregions (Fig. 1A). Oliveira et al. (2017) identified higher rainfall in March and April in the north, between December and March in the southwest, and between April and July on the east coast of NEB. The Amazon and Atlantic Forest biomes had the highest RMSE values. This can be explained by the greater volume of precipitated water in these biomes. In these regions, the average annual precipitation is greater than 1200 mm, unlike the rain gauges in the Caatinga and Cerrado biomes, which record average annual accumulated rainfall of less than 800 mm (Alvares et al., 2013). When evaluating the r and RRMSE metrics, the rainy months present the best performance. There was a reduction in the r value on an annual scale, and the PBIAS values did not change significantly. This indicates that the monthly rainfall errors were not random but are characterized by a positive or negative bias (Duan et al., 2016). The Amazon biome of NEB showed excellent correspondence between satellite and observed data because remote sensing pre-




Fig. 9. Spatial distribution of mean annual precipitation for the period 2001–2019 from observed precipitation and precipitation products (CHIRPS, ERA5-Land, IMERG, TerraClimate, and TRMM).

precipitation estimations assimilate a higher frequency of high-intensity events (Sun et al., 2018), which is commonly recorded in this biome. In dry regions, the predominance of shallow and warm cumulus clouds (Costa et al., 2000) frustrates the identification of precipitation using satellites (Paredes-Trejo et al., 2017). Beck et al. (2017) highlighted that satellite products have greater uncertainty in regions with more complex and arid topographies. In addition, Paredes-Trejo et al. (2017) highlighted the inability of satellites to capture orographic precipitation in the São Francisco River Basin (NEB). Dinku et al. (2011) suggested that in the dry region, the overestimation of precipitation may be because of sub-cloud evaporation and in the mountainous region, the underestimation may be because of the warm orographic rain process. Nogueira et al. (2018) indicated that TRMM and CHIRPS data can be alternatives to observed precipitation data and can be used to compensate the lack of data from weather stations.

5. Conclusion

In this study, we conducted a comprehensive evaluation of the latest versions of five gridded precipitation products (CHIRPS, TRMM, IMERG, ERA5-Land, and TerraClimate) in NEB using observed precipitation from 2001 to 2019. NEB has different biomes and climatic conditions; therefore, it is a good representative for evaluating the performance of these products. This study presents a new contribution to the global view of the performance of various precipitation products and serves as a reference for managers and researchers to select the ideal product for its intended application and its associated uncertainties. The evaluation was conducted on monthly, spatial seasonal and annual scales in NEB.

Our evaluation found that, considering all evaluation metrics, CHIRP, IMERG, and TRMM can be regarded as comparatively superior to the other products. TerraClimate and ERA5-Land had the poorest performance, with a bias towards underestimation. In addition, our seasonal analysis showed that the best RRMSE values were recorded during the rainy season (February–May), and January had the highest r value, with averages greater than 0.8 for all products. The results suggest that the performance of satellite products depends on the characteristics of each biome and the precipitation system. Our results indicate that the satellite-based precipitation products (CHIRP, IMERG, and TRMM) generally outperform model-based precipitation products (TerraClimate and ERA5-Land). Both satellite-based and model-based products had the least effective performance metrics in the Atlantic Forest biome, with a tendency to underestimate the precipitation.

This study demonstrates that precipitation products contribute to a better understanding of the spatial and temporal variability of precipitation. In addition, this research serves as a reference for the choice of ideal product precipitation data with associated uncertainties and can support hydrological modeling studies, drought monitoring; assist in managing water resources in regions with a scarcity of rain gauge stations, and other applications. Finally, studies that evaluate precipitation products at other time scales (hourly and daily) and during climatic extremes are recommended for future research.

Ethical

All ethical practices have been followed in relation to the development, writing, and publication of this research article.

Credit author statement

João M. de Andrade: Conceptualization, Software, Validation, Methodology, Investigation Visualization, Writing- Original draft preparation and Writing - Review & Editing. **Alfredo R. Neto:** Conceptualization, Methodology, Investigation, Visualization, Writing- Original draft preparation and Writing - Review & Editing. **Ulisses A. Bezerra:** Data Survey and Writing - Original draft preparation, Writing - Review & Editing. **Ana C.C. Moraes:** Supervision and Writing - Review & Editing. **Suzana M. G. L. Montenegro:** Formal analysis, Resources and Writing - Review & Editing.

Declaration of competing interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Data availability

The authors are unable or have chosen not to specify which data has been used.

Acknowledgements

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) Finance Code 001. This study was also financed in part by the National Council for Scientific and Technological Development (CNPq), grant numbers 441951/2020-1 and 313392/2020-0, the second and fifth authors are supported by the CNPq; Universal MCTIC/CNPq grant number 431980/2018-7 and project CNPq/MCTIC/BRICS-STI N 29/2017 grant number 442335/2017-2.

References

- Abatzoglou, J.T., Dobrowski, S.Z., Parks, S.A., Hegewisch, K.C., 2018. TerraClimate, a high resolution global dataset of monthly climate and climatic water balance from 1958–2015. *Sci. Data* 5 (1). <https://doi.org/10.1038/sdata.2017.191>.
- Abdi, O., 2019. Climate triggered insect defoliators and forest fires using multitemporal Landsat and TerraClimate data in NE Iran: an application of GEOBIA TreeNet and panel data analysis. *Sensors* 19 (18), 3965. <https://doi.org/10.3390/s19183965>.
- Ahamed, A., Knight, R., Alam, S., Pauloo, R., Melton, F., 2022. Assessing the utility of remote sensing data to accurately estimate changes in groundwater storage. *Sci. Total Environ.* 807, 150635. <https://doi.org/10.1016/j.scitotenv.2021.150635>.
- Almago, A., Oliveira, P.T.S., Rosolem, R., Hagemann, S., Nobre, C.A., 2020. Performance evaluation of Eta/HadGEM2-ES and Eta/MIROC5 precipitation simulations over Brazil. *Atmos. Res.* 244, 105053. <https://doi.org/10.1016/j.atmosres.2020.105053>.
- Alvares, C.A., Stape, J.L., Sentelhas, P.C., Gonçalves, J.D.M., Sparovek, G., 2013. Köppen's climate classification map for Brazil. *Meteorol. Z.* 22 (6), 711–728. <https://doi.org/10.1127/0941-2948/2013/0507>.
- ANA – Agência Nacional de Águas, 2020. USO DA ÁGUA NA AGRICULTURA DE SEQUEIRO NO BRASIL (2013-2017). ANA, Brasília-DF, pp. 1–63. https://biblioteca.ana.gov.br/sophia_web/acervo/detalhe/82410 (Accessed 2 September 2022).
- Andrade, J., Cunha, J., Silva, J., Rufino, I., Galvão, C., 2021. Evaluating single and multi-date Landsat classifications of land-cover in a seasonally dry tropical forest. *Remote Sens. Appl.: Soc. Environ.* 22, 100515. <https://doi.org/10.1016/j.rsase.2021.100515>.
- Arshad, M., Ma, X., Yin, J., Ullah, W., Ali, G., Ullah, S., Ullah, I., 2021. Evaluation of GPM-IMERG and TRMM-3B42 precipitation products over Pakistan. *Atmos. Res.* 249, 105341. <https://doi.org/10.1016/j.atmosres.2020.105341>.
- Baethgen, W.E., Goddard, L., 2013. Latin American perspectives on adaptation of agricultural systems to climate variability and change. In: *Handbook of Climate Change and Agroecosystems: Global and Regional Aspects and Implications—Joint Publication with the American Society of Agronomy. Crop Science Society of America, and Soil Science Society of America*, pp. 57–72.
- Barbosa, H.A., Kumar, T.L., 2016. Influence of rainfall variability on the vegetation dynamics over Northeastern Brazil. *J. Arid Environ.* 124, 377–387. <https://doi.org/10.1016/j.jaridenv.2015.08.015>.
- Beck, H.E., Vergopolan, N., Pan, M., Levizzani, V., Van Dijk, A.I., Weedon, G.P., Wood, E.F., 2017. Global-scale evaluation of 22 precipitation datasets using gauge observations and hydrological modeling. *Hydrol. Earth Syst. Sci.* 21 (12), 6201–6217.
- Beuchle, R., Grecchi, R.C., Shimabukuro, Y.E., Seliger, R., Eva, H.D., Sano, E., Achard, F., 2015. Land cover changes in the Brazilian Cerrado and Caatinga biomes from 1990 to 2010 based on a systematic remote sensing sampling approach. *Appl. Geogr.* 58, 116–127. <https://doi.org/10.1016/j.apgeog.2015.01.017>.
- Brito, C.S., da Silva, R.M., Santos, C.A.G., Neto, R.M.B., Coelho, V.H.R., 2021. Monitoring meteorological drought in a semiarid region using two long-term satellite-estimated rainfall datasets: a case study of the Piranhas River basin, northeastern Brazil. *Atmos. Res.* 250, 105380. <https://doi.org/10.1016/j.atmosres.2020.105380>.
- Brito, C.S., da Silva, R.M., Santos, C.A.G., Brasil Neto, R.M., Coelho, V.H.R., 2022. Long-term basin-scale comparison of two high-resolution satellite-based remote sensing datasets for assessing rainfall and erosivity in a basin in the Brazilian semiarid region. *Theor. Appl. Climatol.* 147 (3), 1049–1064. <https://doi.org/10.1007/s00704-021-03857-w>.
- Brocca, L., Massari, C., Pellarin, T., Filippucci, P., Ciabatta, L., Camici, S., Fernández-Prieto, D., 2020. River flow prediction in data scarce regions: soil moisture integrated satellite rainfall products outperform rain gauge observations in West Africa. *Sci. Rep.* 10 (1), 1–14. <https://doi.org/10.1038/s41598-020-69343-x>.
- Costa, A.A., de Oliveira, C.J., de Oliveira, J.C.P., da Costa Sampaio, A.J., 2000. Microphysical observations of warm cumulus clouds in Ceara, Brazil. *Atmos. Res.* 54 (2–3), 167–199. [https://doi.org/10.1016/S0169-8095\(00\)00045-4](https://doi.org/10.1016/S0169-8095(00)00045-4).
- Costa, R.L., de Mello Baptista, G.M., Gomes, H.B., dos Santos Silva, F.D., da Rocha Júnior, R.L., de Araújo Salvador, M., Herdies, D.L., 2020. Analysis of climate extremes indices over northeast Brazil from 1961 to 2014. *Weather Clim. Extrem.* 28, 100254. <https://doi.org/10.1016/j.wace.2020.100254>.
- Cunha, A.P.M., Alvalá, R.C., Nobre, C.A., Carvalho, M.A., 2015. Monitoring vegetative drought dynamics in the Brazilian semiarid region. *Agric. For. Meteorol.* 214, 494–505. <https://doi.org/10.1016/j.agrformet.2015.09.010>.
- Dahri, Z.H., Moors, E., Ludwig, F., Ahmad, S., Khan, A., Ali, I., Kabat, P., 2018. Adjustment of measurement errors to reconcile precipitation distribution in the high-altitude Indus basin. *Int. J. Climatol.* 38 (10), 3842–3860. <https://doi.org/10.1002/joc.5539>.
- Dembélé, M., Zwart, S.J., 2016. Evaluation and comparison of satellite-based rainfall products in Burkina Faso, West Africa. *Int. J. Rem. Sens.* 37 (17), 3995–4014. <https://doi.org/10.1080/01431161.2016.1207258>.
- Dinku, T., Ceccato, P., Connor, S.J., 2011. Challenges of satellite rainfall estimation over mountainous and arid parts of east Africa. *Int. J. Rem. Sens.* 32 (21), 5965–5979. <https://doi.org/10.1080/01431161.2010.499381>.
- Duan, Z., Liu, J., Tuo, Y., Chiogna, G., Disse, M., 2016. Evaluation of eight high spatial resolution gridded precipitation products in Adige Basin (Italy) at multiple temporal and spatial scales. *Sci. Total Environ.* 573, 1536–1553. <https://doi.org/10.1016/j.scitotenv.2016.08.213>.
- Duarte, L.D.S., Bergamin, R.S., Marcilio-Silva, V., Seger, G.D.D.S., Marques, M.C.M., 2014. Phylobetadiversity among forest types in the Brazilian Atlantic Forest complex. *PLoS One* 9 (8), e105043. <https://doi.org/10.1371/journal.pone.0105043>.

- Dubey, S., Gupta, H., Goyal, M.K., Joshi, N., 2021. Evaluation of precipitation datasets available on Google earth engine over India. *Int. J. Climatol.* <https://doi.org/10.1002/joc.7102>.
- Ferreira, P.M.D.L., Paz, A.R.D., Bravo, J.M., 2020. Objective functions used as performance metrics for hydrological models: state-of-the-art and critical analysis. *RBRH* 25. <https://doi.org/10.1590/2318-0331.252020190155>.
- Freitas, E.D.S., Coelho, V.H.R., Xuan, Y., de Cd Melo, D., Gadelha, A.N., Santos, E.A., Almeida, C.D.N., 2020. The performance of the IMERG satellite-based product in identifying sub-daily rainfall events and their properties. *J. Hydrol.* 589, 125128. <https://doi.org/10.1016/j.jhydrol.2020.125128>.
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., et al., 2015. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Sci. Data* 2 (1), 1–21. <https://doi.org/10.1038/sdata.2015.66>.
- Gadelha, A.N., Coelho, V.H.R., Xavier, A.C., Barbosa, L.R., Melo, D.C., Xuan, Y., et al., 2019. Grid box-level evaluation of IMERG over Brazil at various space and time scales. *Atmos. Res.* 218, 231–244. <https://doi.org/10.1016/j.atmosres.2018.12.001>.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R., 2017. Google earth engine: planetary-scale geospatial analysis for everyone. *Rem. Sens. Environ.* 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>.
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., et al., 2020. The ERA5 global reanalysis. *Q. J. R. Meteorol. Soc.* 146 (730), 1999–2049. <https://doi.org/10.1002/qj.3803>.
- Hobouchian, M.P., Salio, P., Skabar, Y.G., Vila, D., Garreaud, R., 2017. Assessment of satellite precipitation estimates over the slopes of the subtropical Andes. *Atmos. Res.* 190, 43–54. <https://doi.org/10.1016/j.atmosres.2017.02.006>.
- Huffman, G.J., Bolvin, D.T., Nelkin, E.J., Wolff, D.B., Adler, R.F., Gu, G., Stocker, E.F., 2007. The TRMM multisatellite precipitation analysis (TMPA): quasi-global, multiyear, combined sensor precipitation estimates at fine scales. *J. Hydrometeorol.* 8 (1), 38–55. <https://doi.org/10.1175/JHM560.1>.
- Huffman, G.J., Stocker, E.F., Bolvin, D.T., Nelkin, E.J., Tan, J., 2019. GPM IMERG Final Precipitation L3 Half Hourly 0.1 Degree X 0.1 Degree V06. Greenbelt, MD, Goddard Earth Sciences Data and Information Services Center (GES DISC). <https://doi.org/10.5067/GPM/IMERG/3B-HH/06> (Accessed 17 September 2021).
- Hurtado, S.I., Zaninelli, P.G., Agosta, E.A., Ricetti, L., 2021. Infilling methods for monthly precipitation records with poor station network density in Subtropical Argentina. *Atmos. Res.* 254, 105482. <https://doi.org/10.1016/j.atmosres.2021.105482>.
- IBGE, Instituto Brasileiro de Geografia e Estatística, 2019. Censo Agropecuário 2017: Resultados Definitivos, vol. 8. Censo agropec, Rio de Janeiro. 1–105. https://biblioteca.ibge.gov.br/visualizacao/periodicos/3096/agro_2017_resultados_definitivos.pdf (Accessed 2 September 2022).
- Katsanos, D., Retalis, A., Michaelides, S., 2016. Validation of a high-resolution precipitation database (CHIRPS) over Cyprus for a 30-year period. *Atmos. Res.* 169, 459–464. <https://doi.org/10.1016/j.atmosres.2015.05.015>.
- Kidd, C., Huffman, G., 2011. Global precipitation measurement. *Meteorol. Appl.* 18 (3), 334–353. <https://doi.org/10.1002/met.284>.
- Kidd, C., Becker, A., Huffman, G.J., Muller, C.L., Joe, P., Skofronick-Jackson, G., Kirschbaum, D.B., 2017. So, how much of the Earth's surface is covered by rain gauges? *Bull. Am. Meteorol. Soc.* 98 (1), 69–78. <https://doi.org/10.1175/BAMS-D-14-00283.1>.
- Kirschbaum, D.B., Huffman, G.J., Adler, R.F., Braun, S., Garrett, K., Jones, E., Zaitchik, B.F., 2017. NASA's remotely sensed precipitation: a reservoir for applications users. *Bull. Am. Meteorol. Soc.* 98 (6), 1169–1184. <https://doi.org/10.1175/BAMS-D-15-00296.1>.
- Longo-Minnolo, G., Varella, D., Consoli, S., Pappalardo, S., Ramírez-Cuesta, J.M., 2022. Assessing the use of ERA5-Land reanalysis and spatial interpolation methods for retrieving precipitation estimates at basin scale. *Atmos. Res.* 106131. <https://doi.org/10.1016/j.atmosres.2022.106131>.
- Lopez, P., 2011. Direct 4D-Var assimilation of NCEP stage IV radar and gauge precipitation data at ECMWF. *Mon. Weather Rev.* 139 (7), 2098–2116. <https://doi.org/10.1175/2010MWR3565.1>.
- Lucena, D.B., Gomes Filho, M.F., Servain, J., 2011. Avaliação do impacto de eventos climáticos extremos nos oceanos pacífico e atlântico sobre a estação chuvosa no nordeste do Brasil. *Revista Brasileira de Meteorologia* 26 (2), 297–312. <https://doi.org/10.1590/S0102-77862011000200013>.
- Luo, X., Wu, W., He, D., Li, Y., Ji, X., 2019. Hydrological simulation using TRMM and CHIRPS precipitation estimates in the lower Lancang-Mekong river basin. *Chin. Geogr. Sci.* 29 (1), 13–25. <https://doi.org/10.1007/s11769-019-1014-6>.
- Maggioni, V., Sapiano, M.R., Adler, R.F., Tian, Y., Huffman, G.J., 2014. An error model for uncertainty quantification in high-time-resolution precipitation products. *J. Hydrometeorol.* 15 (3), 1274–1292. <https://doi.org/10.1175/JHM-D-13-0112.1>.
- Marengo, J.A., Torres, R.R., Alves, L.M., 2017. Drought in Northeast Brazil—past, present, and future. *Theor. Appl. Climatol.* 129 (3), 1189–1200. <https://doi.org/10.1007/s00704-016-1840-8>.
- Martins, M.A., Tomasella, J., Dias, C.G., 2019. Maize yield under a changing climate in the Brazilian Northeast: impacts and adaptation. *Agric. Water Manag.* 216, 339–350. <https://doi.org/10.1016/j.agwat.2019.02.011>.
- Melo, D.D.C., Xavier, A.C., Bianchi, T., Oliveira, P.T., Scanlon, B.R., Lucas, M.C., Wendland, E., 2015. Performance evaluation of rainfall estimates by TRMM Multi-satellite Precipitation Analysis 3B42V6 and V7 over Brazil. *J. Geophys. Res. Atmos.* 120 (18), 9426–9436. <https://doi.org/10.1002/2015JD023797>.
- Medeiros, R., Andrade, J., Ramos, D., Moura, M., Pérez Marín, A.M., dos Santos, C.A., et al., 2022. Remote sensing phenology of the Brazilian Caatinga and its environmental drivers. *Rem. Sens.* 14 (11), 2637. <https://doi.org/10.3390/rs14112637>.
- Mokhtari, S., Sharafati, A., Raziei, T., 2022. Satellite based streamflow simulation using CHIRPS satellite precipitation product in Shah Bahram Basin, Iran. *Acta Geophys.* 1–14. <https://doi.org/10.1007/s11600-021-00724-0>.
- Mu, Y., Biggs, T., Shen, S.S., 2021. Satellite-based precipitation estimates using a dense rain gauge network over the Southwestern Brazilian Amazon: implication for identifying trends in dry season rainfall. *Atmos. Res.* 261, 105741. <https://doi.org/10.1016/j.atmosres.2021.105741>.
- Muñoz Sabater, J., 2019. ERA5 Land Hourly Data from 1981 to Present. Copernicus Climate Change Service (C3S) Climate Data Store (CDS). <https://doi.org/10.24381/cds.e2161bac> (Accessed 10 September 2021).
- Nazeer, A., Maskey, S., Skaugen, T., McClain, M.E., 2022. Simulating the hydrological regime of the snow fed and glacierised Gilgit Basin in the Upper Indus using global precipitation products and a data parsimonious precipitation-runoff model. *Sci. Total Environ.* 802, 149872. <https://doi.org/10.1016/j.scitotenv.2021.149872>.
- Nelson, D.R., Finan, T.J., 2009. Praying for drought: persistent vulnerability and the politics of patronage in Ceará, Northeast Brazil. *Am. Anthropol.* 111 (3), 302–316. <https://doi.org/10.1111/j.1548-1433.2009.01134.x>.
- Nogueira, S.M.C., Moreira, M.A., Lordelo Volpato, M.M., 2018. Evaluating precipitation estimates from eta, TRMM and CHIRPS data in the south southeast region of minas gerais state—Brazil. *Rem. Sens.* 10 (2), 313. <https://doi.org/10.3390/rs10020313>.
- Oliveira, P.T., Santos e Silva, C.M., Lima, K.C., 2017. Climatology and trend analysis of extreme precipitation in subregions of Northeast Brazil. *Theor. Appl. Climatol.* 130 (1–2), 77–90. <https://doi.org/10.1007/s00704-016-1865-z>.
- Oliveira, R., Maggioni, V., Vila, D., Porcaccia, L., 2018. Using satellite error modeling to improve GPM-Level 3 rainfall estimates over the central Amazon region. *Rem. Sens.* 10 (2), 336. <https://doi.org/10.3390/rs10020336>.
- Paredes Trejo, F.J., Barbosa, H.A., Kumar, T.L., 2017. Validating CHIRPS based satellite precipitation estimates in Northeast Brazil. *J. Arid Environ.* 139, 26–40. <https://doi.org/10.1016/j.jaridenv.2016.12.009>.
- Palharini, R.S.A., Vila, D.A., 2017. Climatological behavior of precipitating clouds in the Northeast region of Brazil. *Adv. Meteorol.* 1–12. <https://doi.org/10.1155/2017/5916150>.
- Pedreira, A.L.P., Biudes, M.S., Machado, N.G., Vourlitis, G.L., Geli, H.M., Santos, L.O.F.D., Neto, N.L., 2021. Assessment of remote sensing and Re-analysis estimates of regional precipitation over mato grosso. Brazil. *Water* 13 (3), 333. <https://doi.org/10.3390/w13030333>.
- Pollock, M.D., O'Donnell, G., Quinn, P., Dutton, M., Black, A., Wilkinson, M.E., O'Connell, P.E., 2018. Quantifying and mitigating wind-induced undercatch in rainfall measurements. *Water Resour. Res.* 54 (6), 3863–3875. <https://doi.org/10.1029/2017WR022421>.
- Prakash, S., 2019. Performance assessment of CHIRPS, MSWEP, SM2RAIN CCI, and TMPA precipitation products across India. *J. Hydrol.* 571, 50–59. <https://doi.org/10.1016/j.jhydrol.2019.01.036>.
- Ramirohetra, J., Sultan, B., Baron, C., Gaiser, T., Gosset, M., 2013. How satellite rainfall estimate errors may impact rainfed cereal yield simulation in West Africa. *Agric. For. Meteorol.* 180, 118–131. <https://doi.org/10.1016/j.agrformet.2013.05.010>.
- Rodrigues, D.T., Gonçalves, W.A., Spyrides, M.H., Santos e Silva, C.M., de Souza, D.O., 2020. Spatial distribution of the level of return of extreme precipitation events in Northeast Brazil. *Int. J. Climatol.* 40 (12), 5098–5113. <https://doi.org/10.1002/joc.6507>.

- Rodrigues, D.T., Santos e Silva, C.M., dos Reis, J.S., Palharini, R.S.A., Cabral Júnior, J.B., da Silva, H.J.F., Gonçalves, W.A., 2021. Evaluation of the integrated multi-Satellite Retrievals for the global precipitation measurement (IMERG) product in the São Francisco basin (Brazil). *Water* 13 (19), 2714. <https://doi.org/10.3390/w13192714>.
- Rodrigues, R.R., McPhaden, M.J., 2014. Why did the 2011–2012 La Niña cause a severe drought in the Brazilian Northeast? *Geophys. Res. Lett.* 41 (3), 1012–1018. <https://doi.org/10.1002/2013GL058703>.
- Rozante, J.R., Vila, D.A., Barboza Chiquetto, J., Fernandes, A.D.A., Souza Alvim, D., 2018. Evaluation of TRMM/GPM blended daily products over Brazil. *Rem. Sens.* 10 (6), 882. <https://doi.org/10.3390/rs10060882>.
- Sampson, C.C., Fewtrell, T.J., O'Loughlin, F., Pappenberger, F., Bates, P.B., Freer, J.E., Cloke, H.L., 2014. The impact of uncertain precipitation data on insurance loss estimates using a flood catastrophe model. *Hydrol. Earth Syst. Sci.* 18 (6), 2305–2324. <https://doi.org/10.5194/hess-18-2305-2014>.
- Sano, E.E., Rodrigues, A.A., Martins, E.S., Bettiol, G.M., Bustamante, M.M., Bezerra, A.S., Bolfe, E.L., 2019. Cerrado ecoregions: a spatial framework to assess and prioritize Brazilian savanna environmental diversity for conservation. *J. Environ. Manag.* 232, 818–828. <https://doi.org/10.1016/j.jenvman.2018.11.108>.
- Santana, R.O., Delgado, R.C., Schiavetti, A., 2020. The past, present and future of vegetation in the Central Atlantic Forest Corridor, Brazil. *Remote Sens. Appl.: Soc. Environ.* 20, 100357. <https://doi.org/10.1016/j.rsase.2020.100357>.
- Santos, C.A.G., Brasil Neto, R.M., Passos, J.S. de A., da Silva, R.M., 2017. Drought assessment using a TRMM-derived standardized precipitation index for the upper São Francisco River basin, Brazil. *Environ. Monit. Assess.* 189 (6). <https://doi.org/10.1007/s10661-017-5948-9>.
- Schleiss, M., Olsson, J., Berg, P., Niemi, T., Kokkonen, T., Thorndahl, S., Pulkkinen, S., 2020. The accuracy of weather radar in heavy rain: a comparative study for Denmark, The Netherlands, Finland and Sweden. *Hydrol. Earth Syst. Sci.* 24 (6), 3157–3188. <https://doi.org/10.5194/hess-24-3157-2020>.
- Shen, Y., Xiong, A., Wang, Y., Xie, P., 2010. Performance of high-resolution satellite precipitation products over China. *J. Geophys. Res. Atmos.* 115 (D2). <https://doi.org/10.1029/2009JD012097>.
- Silva, A.M., Silva, R.M.D., Santos, C.A.G., Linhares, F.M., Xavier, A.P.C., 2022. Modeling the effects of future climate and land-use changes on streamflow in a headwater basin in the Brazilian Caatinga biome. *Geocarto Int.* 1–30. <https://doi.org/10.1080/10106049.2022.2068672>.
- Sun, Q., Miao, C., Duan, Q., Ashouri, H., Sorooshian, S., Hsu, K.L., 2018. A review of global precipitation data sets: data sources, estimation, and intercomparisons. *Rev. Geophys.* 56 (1), 79–107. <https://doi.org/10.1002/2017RG000574>.
- Taniminia, H., Salehi, B., Mahdianpari, M., Quackenbush, L., Adeli, S., Brisco, B., 2020. Google Earth Engine for geo-big data applications: a meta-analysis and systematic review. *ISPRS J. Photogrammetry Remote Sens.* 164, 152–170. <https://doi.org/10.1016/j.isprsjprs.2020.04.001>.
- Tan, X., Wu, Y., Liu, B., Chen, S., 2020. Inconsistent changes in global precipitation seasonality in seven precipitation datasets. *Clim. Dynam.* 54 (5), 3091–3108. <https://doi.org/10.1007/s00382-020-05158-w>.
- Tonello, K.C., Rosa, A.G., Pereira, L.C., Matus, G.N., Guandique, M.E.G., Navarrete, A.A., 2021. Rainfall partitioning in the Cerrado and its influence on net rainfall nutrient fluxes. *Agric. For. Meteorol.* 303, 108372. <https://doi.org/10.1016/j.agrformet.2021.108372>.
- TRMM - TROPICAL RAINFALL MEASURING MISSION, 2017. PRECIPITATION PROCESSING SYSTEM - File Specification for TRMM Products, p. 329. version 7.006. <https://earthurhou.pps.eosdis.nasa.gov/Documents/filespec/TRMM.V7.pdf> (Accessed 3 October 2019).
- Toté, C., Patricio, D., Boogaard, H., Van der Wijngaart, R., Tarnavsky, E., Funk, C., 2015. Evaluation of satellite rainfall estimates for drought and flood monitoring in Mozambique. *Rem. Sens.* 7 (2), 1758–1776. <https://doi.org/10.3390/rs70201758>.
- Vieira, R.D.S.P., Tomasella, J., Alvalá, R.C.S., Sestini, M.F., Affonso, A.G., Rodriguez, D.A., Santana, M.O., 2015. Identifying areas susceptible to desertification in the Brazilian northeast. *Solid Earth* 6 (1), 347–360. <https://doi.org/10.5194/se-6-347-2015>.
- Xavier, A.C., King, C.W., Scanlon, B.R., 2016. Daily gridded meteorological variables in Brazil (1980–2013). *Int. J. Climatol.* 36 (6), 2644–2659. <https://doi.org/10.1002/joc.4518>.
- Xavier, A. C., Scanlon, B. R., King, C. W., & Alves, A. I. New Improved Brazilian Daily Weather Gridded Data (1961–2020). *Int. J. Climatol.* <https://doi.org/10.1002/joc.7731>.
- Xu, J., Ma, Z., Yan, S., Peng, J., 2022. Do ERA5 and ERA5-land precipitation estimates outperform satellite-based precipitation products? A comprehensive comparison between state-of-the-art model-based and satellite-based precipitation products over mainland China. *J. Hydrol.* 605, 127353. <https://doi.org/10.1016/j.jhydrol.2021.127353>.

APÊNDICE B – EFFICIENCY OF GLOBAL PRECIPITATION DATASETS IN TROPICAL AND SUBTROPICAL CATCHMENTS REVEALED BY LARGE SAMPLING HYDROLOGICAL MODELLING

Journal of Hydrology 633 (2024) 131016



Contents lists available at ScienceDirect

Journal of Hydrology

journal homepage: www.elsevier.com/locate/jhydrol



Research papers

Efficiency of global precipitation datasets in tropical and subtropical catchments revealed by large sampling hydrological modelling

João M. Andrade^{a,b,*}, Alfredo Ribeiro Neto^a, Rodolfo L.B. Nóbrega^{b,d}, Miguel A. Rico-Ramirez^c, Suzana M.G.L. Montenegro^b

^a Federal University of Pernambuco, Department of Civil and Environmental Engineering, Recife, Brazil

^b University of Bristol, School of Geographical Sciences, Bristol, BS8 1SS, United Kingdom

^c University of Bristol, School of Civil, Aerospace and Design Engineering, Bristol, BS8 1TR, United Kingdom

^d University of Bristol, Cabot Institute for the Environment, Bristol, UK



ARTICLE INFO

Keywords:
Remote sensing
Rainfall-runoff modelling
Satellite precipitation products
Reanalysis
Brazil

ABSTRACT

Satellite-based and reanalysis precipitation products are widely adopted as complementary information to in situ measurements for estimating river discharge using hydrological modelling. However, there is still a notable research gap in the literature associated with assessing the accuracy of satellite-based or reanalysis products in different tropical and sub-tropical catchments at large-sampling hydrological modelling with sensitivity analysis. We investigated the accuracy of precipitation, hydrological model performance and parameter sensitivity related to seven precipitation data sets based on satellite and reanalysis products, i.e., CHIRPS, TRMM, GLDAS, IMERG, MERRA-2, PERSIANN-CDR, and ERA5 over 714 contrasting tropical and subtropical catchments located in Brazil. We used the Génie Rural Journalier 4 (GR4J) hydrological model to simulate the hydrological processes of the different catchments with two approaches for the calibration: using measured ground-based precipitation data (approach I) or using each individual satellite/reanalysis precipitation products (approach II) to calibrate the models. The results showed that the precipitation products tend to overestimate precipitation, with the exception of ERA5 and MERRA-2. CHIRPS is the only product that produces unbiased precipitation estimates for most catchments. The model calibration using each precipitation product individually improved the hydrological model performance. CHIRPS, IMERG, and MERRA-2 showed good accuracy in terms of both, precipitation estimation and hydrological simulation performance in the calibration period. In the validation period, the best products in terms of KGE were CHIRPS, IMERG and TRMM (KGE > 0.64). The errors in precipitation products are better compensated via hydrological modelling in wet regions. The model parameter sensitivity varies according to precipitation input, climate, and catchment aridity. Overall, all seven products exhibited their worst hydrological performance in arid regions. This study helps to improve our understanding of the catchment response in tropical and subtropical regions while also providing key insights into the reliability of satellite/reanalysis rainfall products for streamflow simulation. This study is valuable in hydrometeorological applications, climate change assessment, water resources and disaster management, especially in regions with a relatively sparse density of precipitation stations.

1. Introduction

Precipitation represents the greatest terrestrial water flux, and it is one of the most important atmospheric variables in studies dealing with the energy, carbon, and water global cycles (Baethgen and Goddard, 2013; Toté et al., 2015). However, the monitoring of precipitation, especially in developing countries, has been impacted by the lack of

monitoring systems, the high proportion of missing data, and the short-lived time series that make the reliable analysis of rainfall data unfeasible (Xavier et al., 2016). For instance, in many regions of Africa and South America, the density of rain gauge networks is approximately one station per 100,000 km² (Brocca et al., 2020).

The development of data assimilation and remote sensing technology allowed the production of high-quality precipitation datasets by satellite

* Corresponding author at: Federal University of Pernambuco, Department of Civil and Environmental Engineering, Recife, Brazil.

E-mail addresses: joao.jma@ufpe.br, andradejmn@gmail.com (J.M. Andrade), alfredo.ribeiro@ufpe.br (A. Ribeiro Neto), r.nobrega@bristol.ac.uk (R.L.B. Nóbrega), M.A.Rico-Ramirez@bristol.ac.uk (M.A. Rico-Ramirez), suzanam.ufpe@gmail.com (S.M.G.L. Montenegro).

<https://doi.org/10.1016/j.jhydrol.2024.131016>

Received 5 October 2023; Received in revised form 16 February 2024; Accepted 18 February 2024

Available online 5 March 2024

0022-1694/© 2024 The Authors. Published by Elsevier B.V. This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0/>).

and reanalysis methods (Wang et al., 2020a). These products offer an opportunity for applying and assessing the time-space variability of the precipitation at contrasting spatial and temporal scales for hydrological and climate applications (Dembélé and Zwart, 2016; Duan et al., 2016; Brocca et al., 2020). Precipitation datasets based on satellite and reanalysis products are widely used as complementary information to in situ measurements for estimating river discharge using hydrological modelling (Khatakho et al., 2021; Su et al., 2021). The performance of these datasets depends on the region (Maggioni and Massari, 2018; Wang et al., 2020a; Dubey et al., 2021; Xu et al., 2022) because they are subjected to errors, such as the ones caused by climate factors (Maggioni et al., 2016), a variety of surface conditions (Bytheway and Kummerow, 2010), and the type of precipitation measurement (Villarini et al., 2009).

Although many studies have identified errors and uncertainties related to environmental and measurement characteristics, only a few studies assessed their implications in streamflow estimates using hydrological models (Camici et al., 2018; Wang et al., 2023). Usually, in this context, studies in hydrology address a research question specific to a local reality or evaluate a single precipitation product (e.g., Li et al., 2012; Yang et al., 2017; Mtibaa and Asano, 2022). In some cases, reanalysis-based precipitation datasets are not considered (e.g., Jiang and Bauer-Gottwein et al., 2019; Su et al., 2021), or referred only to a single specific case study (e.g., Wang et al., 2020a; Moges et al., 2022), or a limited number of catchments (e.g., Stephens et al., 2022; Wanzala et al., 2022; Wei et al., 2023; Wu et al., 2023), limiting the possibilities of analysis to a specific context and, consequently, can not support general conclusions.

Brazil has the largest amount of freshwater available in the world (~12 %) (Levis et al., 2020; Getirana et al., 2021), and ~20 % of the global continental water that flows into oceans comes from its rivers (Getirana, 2016). With an area of ~ 8.5 million km² with diverse topographic, vegetation and soil characteristics distributed across three major climate zones, i.e., humid tropical, subtropical, and semi-arid, the Brazilian territory offers a relevant variety of conditions to assess precipitation products. Most studies in Brazil that evaluated precipitation products did not assess the application of these products in hydrological modelling (e.g., Paredes-Trejo et al., 2017; Cavalcante et al., 2020; Oliveira-Junior et al., 2021; Mu et al., 2021; Ramos Filho et al., 2022). For instance, Melo et al. (2015) evaluated the TRMM precipitation over Brazil and identified poor performance of this product in the Northwest region, while Gadelha et al. (2019) assessed the IMERG product at different temporal and spatial scales and found a slight tendency to overestimate the ground-based rainfall at all timescales. The studies involving hydrological modelling in Brazil generally utilised a limited number of catchments (Falck et al., 2015; Junqueira et al., 2022), and only a few studies (e.g., Almagro et al., 2021b; Reis et al., 2022) have used several catchments in Brazil, but they did not quantify the sensitivity of the hydrological model associated with precipitation products. Thus, there is a notable research gap in the literature associated with assessing the accuracy of satellite-based or reanalysis products in different tropical and sub-tropical catchments for hydrological applications.

To the best of our knowledge, this is the first study that evaluates different precipitation products at large-sampling hydrological modelling with sensitivity analysis in tropical and subtropical catchments with contrasting climate, topography, soil and vegetation. Our aim is to support the guidance on applying precipitation products in hydrological modelling for potential end users in different hydroclimate regions. This is achieved by quantifying the accuracy of the precipitation datasets based on satellite and reanalysis products and evaluating their performance for simulating river discharge using the rainfall-runoff hydrological model Génie Rural Journalier 4 (GR4J) model. The objectives are three-fold: i) to evaluate the quality of seven precipitation products, namely CHIRPS, TRMM, IMERG, PERSIANN-CDR, MERRA-2; GLDAS and ERA5, statistically, using catchment-averaged precipitation from a ground-based rain gauge network; ii) to investigate the use of these

precipitation products in hydrological simulations and their respective accuracy in estimating river discharge, and; (iii) to analyse the sensitivity of hydrological model parameters to different precipitation products.

2. Study area and datasets

2.1 Study area

Brazil has humid tropical, subtropical, and semi-arid major climate zones as defined by Köppen climate classification (Alvares et al., 2013; Fig. 1a); twelve hydrographic regions (Table 1), namely Eastern Northeast (NE) Atlantic (Atlan.), East Atlan., Parnaíba, São Francisco, Western NE Atlan., Tocantins Araguaia, Paraguai, Southeast Atlan., Parana, Amazon, South Atlan., Uruguai; and six biomes: Amazon, Atlantic Forest, Cerrado, Caatinga, Pampa, and Pantanal (Fig. 1). The mean annual precipitation for these regions varies from ~ 750 mm year⁻¹ in Eastern NE Atlan., localised in the semi-arid, where the potential evapotranspiration values are up to ~ 2,000 mm year⁻¹, in the Amazon region. The precipitation regime in Brazil is highly seasonal, with the exception of the hydrographic regions of southern Brazil that have uniform precipitation throughout the year due to the multiple sources of atmospheric moisture (Chagas et al., 2020).

2.2 Datasets

2.2.1 Satellite-based and reanalysis-based precipitation

We evaluated seven satellite and reanalysis precipitation products, i.e., CHIRPS, ERA5, IMERG, GLDAS, MERRA-2, PERSIANN-CDR and TRMM (Table 2). These products were chosen because they are reported to show consistency with ground-based precipitation observations (Dubey et al., 2021; Andrade et al., 2022; Wang et al., 2020b; Xu et al., 2022), although they have not been tested using a hydrological model in different hydroclimate regions of Brazil. These datasets were extracted using the Google Earth Engine (GEE) platform (Gorelick et al., 2017) and superimposed on the catchment areas to calculate the averaged precipitation over each catchment at daily time scale.

The Tropical Rainfall Measuring Mission (TRMM) was launched in 1997 and has been used in the estimation of high-quality precipitation estimates for applications for almost 20 years (Huffman et al., 2007; Kidd and Huffman, 2011). The algorithm 3B43, used by TRMM, averages the precipitation estimates from multiple satellites at the monthly scale and combines it with the Global Precipitation Climatology Centre's (GPCC) surface precipitation gauge analysis (TRMM, 2017). The Global Precipitation Measurement (GPM) was launched in 2014 as a successor to the TRMM services (covering June 2000 to the present), and the Integrated Multi-satellite Retrievals for GPM (IMERG) is a unified algorithm that provides estimations of precipitation, combining data from all passive microwave (PM) instruments in the constellation GPM (Kirschbaum et al., 2017; Huffman et al., 2019).

The Climate Hazards Group InfraRed Precipitation with Station data (CHIRPS) uses satellite products with in-situ data to generate gridded time series (Funk et al., 2015). Three types of information are considered: global climatological data, satellite estimations, and ground measurements, and therefore falling into the category of "satellite-gauge" rainfall product (Duan et al., 2016). The Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks - Climate Data Record (PERSIANN-CDR) is based on the PERSIANN algorithm that applies infrared bands from geostationary satellites (GridSat-B) to estimate precipitation rate and then, to adjust with the monthly product of the Global Precipitation Climatology Project (GPCP) (Ashouri et al., 2015).

The European Centre for Medium-Range Weather Forecasts ReAnalysis 5 (ERA5) is the last generation of the global reanalysis dataset produced by the European Centre for Medium-Range Weather Forecasts (ECMWF) and provides multiple atmospheric and land surface variables




Fig. 1. Location and characteristics of the study region: a) Köppen's climate classification for Brazil (according to [Alvares et al., 2013](#)); Tropical zone (A): without dry season (Af), monsoon (Am), dry winter (Aw) or dry summer (As); Dry zone (B): with semi-arid climate and low latitude and altitude (BSh); Subtropical zone (C): with oceanic climate, without dry season, with hot summer (Cfa) or with temperate summer (Cfb) or subtropical zone with dry winter and hot summer (Cwa) or temperate summer (Cwb). b) Location map containing the 714 catchments (outlets shown by red dots) in which the precipitation products were assessed. Note that the boundaries of each catchment are not shown (only the catchment outlet) due to the large number of catchments. For each hydrographic region, the long-term average precipitation of the area and the average flow of all catchments within it are represented in the sub-frames. The shaded (grey) areas represent the daily flow range for the hydrographic regions. (For interpretation of the references to colour in this figure legend, the reader is referred to the web version of this article).

Table 1

Mean daily values of climatic and hydrological variables for the hydrographic regions of Brazil. Minimum Temperature (Tmin); Maximum Temperature (Tmax); Precipitation (P); Potential Evapotranspiration (PET); Runoff Coefficient (RC).

Hydrographic regions	Tmin (°C)	Tmax (°C)	P (mm/day)	PET (mm/day)	Aridity Index (PET/P)	Runoff (Q) (mm/day)	RC (Q/P)
Eastern NE Atlán.	20.73	30.69	2.10	6.16	2.93	0.19	0.09
East Atlán.	18.74	29.45	2.62	5.49	2.10	0.47	0.18
Parnaíba	21.04	33.15	3.04	6.09	2.00	0.44	0.14
São Francisco	17.46	29.74	3.43	5.58	1.63	0.89	0.26
Western NE Atlán.	22.02	32.78	3.78	5.82	1.54	0.63	0.17
Tocantins-Araguaia	19.91	31.68	4.43	5.56	1.26	1.56	0.35
Paraguay	20.52	32.47	4.39	5.46	1.24	1.82	0.42
Southeast Atlán.	16.34	27.18	4.16	4.91	1.18	1.76	0.42
Parana	15.64	27.14	4.36	5.00	1.15	1.78	0.41
Amazon	21.63	32.11	5.56	5.33	0.96	2.06	0.37
South Atlán.	14.20	23.81	4.69	4.42	0.94	2.71	0.58
Uruguai	13.71	24.19	5.04	4.63	0.92	2.75	0.55

Note: The data are calculated of the catchments within a hydrographic region using data by [Almagro et al., \(2021a\)](#) for the 1980–2010 period. The aridity index is calculated from the mean daily precipitation values and potential evapotranspiration ([Arora, 2002](#)). The hydrographic regions are sorted from the driest (top) to the wettest (bottom) according to the aridity index.

([Hersbach et al., 2020](#)). The Modern-Era Retrospective analysis for Research and Applications, Version 2 (MERRA-2) is the most recent version of global atmospheric reanalysis from NASA's Goddard Earth Observing System Model, Version 5.12.4 (GEOS-5.12.4) ([Gelaro et al.,](#)

[2017](#)). We used the MERRA-2 PRECTOTCORR, in which an adjustment for latitude-dependent bias is implemented as described by [Reichle et al. \(2017\)](#). The NASA Global Land Data Assimilation System Version 2 (GLDAS-2) ingests satellite and ground-based observational data

Table 2
Spatial and temporal coverage and resolution of the precipitation products.

Dataset (version)	Spatial Resolution	Temporal Resolution	Spatial Coverage	Temporal Coverage	References
CHIRPS (v.2)	0.05°	Daily	50°N–50°S	1981–Present	Funk et al. (2015)
ERA5	0.25°	Hourly	Global	1979–Present	Hersbach et al. (2020)
GLDAS-Noah (v2.1)	0.25°	3 h	Global	2000–Present	Rodell et al., (2004)
IMERG (v.6)	0.10°	Half an hour	50°N–50°S	2000–Present	Huffman et al. (2019)
MERRA-2 PREC/TOTCORR	0.5° × 0.625°	Hourly	Global	1980–Present	Gelaro et al. (2017)
PERSIANN-CDR (v.1)	0.25°	Daily	60°N–60°S	1983–Present	Ashouri et al. (2015)
TRMM (3B42 v.7)	0.25°	3 h	50°N–50°S	1998–2019	Huffman et al. (2007)

products using a combination of model and observation data (Rodell et al., 2004; Wang et al., 2020b). The GLDAS 2.1 incorporated atmospheric analysis fields from the National Oceanic and Atmospheric Administration (NOAA)/Global Data Assimilation System (GDAS) as the forcing data (Beaudoin and Rodell, 2020).

2.2.2 Observed flows, precipitation, and evapotranspiration

The observed daily river discharge for the Brazilian catchments were extracted from the Catchment Attributes for Brazil (CABra) dataset (Almagro et al., 2021a) derived from the database of the Brazilian Water Agency (ANA). CABra is a large sample dataset for 735 catchments in Brazil, including more than 100 catchment attributes divided into eight main classes: topography, climate, flow, groundwater, soil, geology, land cover, and hydrological disturbance, i.e., an index that indicates human interactions that can modify catchment water flows, for the 1980–2010 hydrological period.

We used a subselection of catchments with less than 10 % of missing data to cover the 2000–2010 period, resulting in 714 catchments. The 2000–2010 period was used because it is the timeframe during which all products have data available, starting in 2000 (IMERG and GLDAS precipitation products) and ending in 2010 (CABra dataset), this choice ensures consistency in the data and facilitates comparison across the precipitation datasets. From CABra, we extracted the reference precipitation, i.e., ground-based rainfall, and the reference evapotranspiration calculated using the Penman-Monteith method (Allen et al., 1998). Ground-based rainfall and evapotranspiration data used in CABra were extracted from the grid interpolated product (0.25° × 0.25°) developed by Xavier et al. (2016) for the entire Brazilian territory. This dataset used data from 2,890 rain gauges from ANA, and the Department of Waters and Electric Energy of the State of São Paulo (DAEE), and 735 weather stations from 1980 to 2013 of the National Meteorological Institute (Inmet). This data set was averaged over each catchment at daily time scale.

3. Methodology

The experimental design of this work has three parts. In the first part, we assess seven catchment-average precipitation products against ground-based catchment-average rainfall for the period 2001–2010 with a daily time scale. In the second part, these precipitation products are used to drive the parsimonious hydrological model GR4J to evaluate their performance. Two approaches were proposed: (a) approach I - a single model was calibrated for each catchment with ground-based rainfall data and validated with the different precipitation products; (b) approach II, seven models were calibrated and validated for each catchment with each individual precipitation product. In both cases, the data were divided into three periods: a warm-up period (June–2000 to Dec–2000), a calibration period (Jan–2001 to Dec–2005), and validation period (from Jan–2006 to Sep–2010) and the model performance is

evaluated during both calibration and validation periods. Finally, in the third part, we analyse the sensitivity of the hydrological model parameters.

3.1 Calibration and validation of the hydrological model

We used the GR4J hydrological model to simulate river discharge because it has been successfully applied in several studies across the globe (Wu et al., 2019; Satgé et al., 2021; Tarek et al., 2021; Stephens et al., 2022) due its ability to account for groundwater exchanges with aquifers, a distinctive feature compared to reference conceptual models (Hashemi et al., 2022). GR4J uses daily evapotranspiration (E) and precipitation (P) as inputs (Perrin et al., 2003); streamflow (Q) and actual evaporation (E_s) are the outputs, and the soil moisture in the production storage (S) and routing storage (R) are the state variables of the model (Nayak et al., 2021). This model uses four parameters, which represent the maximum capacity of the production store ($X1$, in mm), the groundwater exchange coefficient ($X2$, mm), the maximum day-ahead capacity of the routing store ($X3$, in mm), and the time base of the unit hydrograph ($X4$, day) (Fig. 2) (Perrin et al., 2003; Tegegne et al., 2017).

The first operation is the subtraction of evapotranspiration from precipitation to determine net precipitation (P_n); if P_n is not zero, a part (P_s , the precipitation at the level of S) of P_n fills the production store, it is calculated according to the level S (the actual amount of storage) (Eq. 1). If the amount of precipitation is less than evapotranspiration, the net precipitation is equal to 0, and E_s (Eq.2) is calculated as part of net evapotranspiration capacity (En) (Perrin et al., 2003). The soil moisture in the production store is then updated (Eq.3). A percolation leakage ($Perc$) (Eq.4) from the production store is then calculated as a power function of the reservoir contents (Perrin et al., 2003). The percolation from the soil moisture in the production storage and the direct runoff are added to produce the total quantity of water to reach routing functions (Pr) (Eq. 5).

Pr is divided into two fixed parts. In the first part (Q_0) (Eq.6), 90 % of Pr (delayed flow) is forwarded using a unit hydrograph (UH_1) with a $X4$ time base in days, and then forwarded by a storage capacity $X3$ non-linear linear routing (Nayak et al., 2021). In the second part (Q_1) (Eq.7), 10 % of Pr (fast flow) is forwarded by a UH_2 with twice time base $X4$ (2. $X4$). The amount of groundwater exchange F between the catchment and groundwater is calculated using Eq. 8, where R is the level in the routing storage (Eq. 9), $X3$ is the 'reference' capacity, and $X2$ is the coefficient of water exchange, which is positive when water is imported, negative when water is exported and zero when there is no flow exchange (Mohammadi et al., 2022). Q_r and Q_d are the outflow and forward flows, respectively (Eqs. 10 and 11), which are used to compute the total flow (Q) at the catchment outlet (Eq. 12).

In this study, the GR4J model calibration and runoff simulations were performed using the AirGR package (Coron et al., 2017; Coron et al., 2018) in the R language (R Development Core Team, 2015). The




Fig. 2. Schematic diagram of the GR4J rainfall-runoff model. Adapted: Perrin et al. (2003).

four parameters ($X1$, $X2$, $X3$ and $X4$) of the GR4J model were calibrated using the Michel (Michel, 1991) optimization algorithm, and the Nash-Sutcliffe efficiency (NSE) coefficient (Nash and Sutcliffe, 1970), the most common indicator widely utilized in hydrology (Beck et al., 2017; Stephens et al., 2019), was selected as the objective function. This calibration algorithm combines: (i) a global approach to identify the most likely zone of convergence and a methodical examination of the global parameter space is carried out, and (ii) a local approach, starting with the best parameter set from step (i), where a steepest descent local search approach is used to estimate the optimal parameter set, for parameter estimation (Michel, 1991; Coron et al., 2018). This method needs a lower number of model runs required for convergence (Mathévet et al., 2006) and has shown similar efficiency to more complex global search algorithms (Coron et al., 2018).

3.2 Statistical metrics to evaluate rainfall and river discharge estimates

We used the following statistical metrics to evaluate the performance and quality of precipitation products relative to the observed data product (ground-based rainfall): root mean square error (RMSE), percentage bias (Pbias) and correlation coefficient (r) (Eqs. (13), 14, and 15).

$$RMSE = \left(\frac{\sum_{i=1}^n (Xsim, i - Xobs, i)^2}{n} \right)^{0.5} \quad (13)$$

$$pbias = \frac{\sum_{i=1}^n (Xsim, i - Xobs, i) \cdot 100}{\sum_{i=1}^n Xobs, i} \quad (14)$$

$$r = \frac{\sum_{i=1}^n (Xsim, i - Xsim) \cdot (Xobs, i - Xobs)}{\sqrt{\sum_{i=1}^n (Xsim, i - Xsim)^2 \cdot \sum_{i=1}^n (Xobs, i - Xobs)^2}} \quad (15)$$

where $Xsim, i$ represents the simulated discharge (or a given precipitation product), $Xobs, i$ represents the observed discharge (or precipitation), $Xsim$ and $Xobs$ are their respective averages and n is the number of observations. We additionally used the Kling-Gupta efficiency metric (Eq. (16)) to evaluate the river discharge estimates. This metric is widely used to calibrate and evaluate hydrologic models with observed data (e.g. Mizukami et al., 2019; Brocca et al., 2020; Wanzala et al., 2022). The KGE combines Pearson correlation coefficient (r), bias, and variability, with $\alpha = \frac{\sigma_s}{\sigma_o}$ and $\beta = \frac{\mu_s}{\mu_o}$ where (μ_o, σ_o) and (μ_s, σ_s) are the mean and standard deviation of observations and simulations, respectively (Gupta et al., 2009). The KGE ranges from $-\infty$ to 1 with a perfect score of 1. Values above 0.55 and 0.75 are considered intermediate and good, respectively, while negative KGE values can be considered “not satisfactory” (Schönfelder et al., 2022; Brighenti et al., 2019), however, Knoben et al. (2019) observed that KGE values above -0.41 represented reasonable performance.

$$KGE = 1 - \sqrt{(r - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2} \quad (16)$$

3.3 Sensitivity analysis

The sensitivity analysis was conducted by applying the global Sobol sensitivity method (Sobol, 1993) using the Sensitivity package in R (Iooss et al., 2021) for the GR4J model parameters. The modified NSE (NSE*) was the target function with range $[-1, 1]$ (Shin et al., 2013), it offers the benefit of mitigating the impact of very large negative numbers of the NSE $[-\infty, 1]$ (Shin and Jung, 2022). The Sobol method estimates the parameters' sensitivity by decomposing the model output variance, quantified by the ratio of its contribution to the output variance (Sobol et al., 1993; Shin et al., 2013). In our study, we used the TSI (Total Sensitivity Index), as it provides the total effect of a parameter,

including all its interactions with other parameters. The higher the values of TSI, the more influential the parameter; consequently, parameters with $TSI \approx 0$ can be considered non-influential. This paper uses the Saltelli's scheme (Saltelli, 2002) to calculate TSI with reduced cost by using $n(k+2)$ instead of $n(2k+2)$ with Monte Carlo random sampling method for input variables. When n is the initial sample size, we adopted n equal to 1,000. Moreover, k denotes the number of parameters in the hydrological model (four parameters for the GR4J). Therefore, the total number of samples for sensitivity analysis was 6,000 for each catchment, resulting in 4,284,000 simulations for all 714 catchments and 29,988,000 simulations considering all precipitation datasets.

4 Results

4.1 Accuracy of precipitation products against ground-based rainfall

Figs. 3 and 4 summarise the performance of the different precipitation products. The precipitation products show median r values above 0.55 (Figs. 3 and 4). CHIRPS, MERRA-2, ERA5, and IMERG presented the highest median r values ($r > 0.60$). ERA5 and MERRA-2 showed a tendency to underestimate precipitation with a median Pbias value of -2.5 and -4.7 %, respectively. CHIRPS showed unbiased precipitation estimates (Pbias = 0.1 %), whereas GLDAS, IMERG, PERSIANN-CDR and TRMM tend to overestimate precipitation. The median RMSE values ranged from 5.88 mm/day (MERRA-2) to 7.91 mm/day (TRMM) and higher in the Southern catchments and lower in the Northern catchments.

All hydrographic regions generally presented r values above 0.5 for all precipitation products, with the best r values registered for Sao Francisco, Tocantins-Araguaia, and Parnaiba hydrographic regions (Fig. 5). The products tended to overestimate precipitation, except in the Amazonas and the driest hydrographic regions as East Atlan., and Eastern NE Atlan. (Fig. 5). Additionally, there is a higher recurrence of such underestimate for ERA5 in other basins. As expected, the highest RMSE values were registered in the regions with higher rainfall, such as the Amazon and South Atlan., and Uruguai hydrographic regions with RMSE values above 6 mm/day. The hydrographic regions with an aridity index between 1.24 and 2, mainly in tropical zones with dry winters (Aw) (Fig. 1 and Table 1), showed better performance in terms of the r coefficient. In contrast, Brazil's driest and wettest catchments (Eastern NE Atlan and South Atlan. hydrographic regions) had the poorest performance.

4.2 Hydrological assessment in Brazilian basins

4.2.1 Hydrological simulation analysis based on standard calibration (Approach I)

In the approach I, the hydrological models were calibrated with ground-based precipitation only and evaluated (in the calibration and validation) phases with all precipitation products. The performance of the ground-based rainfall and precipitation products in simulating daily river flow during the calibration (Jan–2001 to Dec–2005) and validation (Jan–2006 to Aug–2010) periods using the GR4J hydrological model is




Fig. 3. Spatial distribution of performance scores for the seven different precipitation products (CHIRPS, ERA5, GLDAS, IMERG, MERRA-2, PERSIANN-CDR, and TRMM) when compared to catchment-averaged ground-based rainfall measurements.




Fig. 4. Boxplots of performance metrics (r , $pbias$, $RMSE$) for the precipitation products (CHIRPS, ERA5, GLDAS, IMERG, MERRA-2, PERSIANN-CDR, and TRMM) for all catchments.




Fig. 5. Median values of performance metrics (r , $pbias$, $RMSE$) for the precipitation products by hydrographic region sorted from the wettest (top) to the driest (bottom) according to the aridity index.

illustrated in Figs. 6 and S1. As expected, the models driven by ground-based precipitation showed the best performance in simulating river discharges for both calibration and validation periods. CHIRPS showed one of the best performances (compared to the rest of the reanalysis precipitation products) in simulating river discharges (Fig. 6). The calibration and validation results indicate that the GR4J model can capture the climatic characteristics of the observed hydrographs in the different hydrological regions of Brazil. For most of the catchments (83.05 %), the GR4J model presents KGE values greater than 0.5 for both the calibration and validation phases of the simulated catchments with the ground-based rainfall.

The median values of the statistical metrics calculated between the

observed and simulated hydrographs using the different precipitation products for all 714 catchments are shown in Table 3. Compared to the simulations based on ground-based rainfall, the simulations with precipitation products exhibited a decrease in performance during the validation and calibration periods (Table 3). The most remarkable differences in the model performance between ground-based rainfall and precipitation products simulations were in Northeast and South Brazil regions (Fig. S1), similar results were obtained in the same regions for the precipitation analysis.

4.2.2 Hydrological simulation analysis based on specific calibration input (Approach II)




Fig. 6. Cumulative density functions (CDF) of the KGE for the ground-based rainfall and the seven different precipitation products in the simulation of daily river flow in the Brazilian basins in the calibration and validation phases.

Table 3

Median and standard deviation (value shown in brackets) of the statistical metrics for discharge simulation for all 714 selected catchments using calibration approach I.

Precipitation product	Calibration			Validation		
	r [0–1]	pbias (%) [−∞–∞]	KGE [−∞–1]	r [0–1]	pbias (%) [−∞–∞]	KGE [−∞–1]
Ground-based rainfall	0.88 (0.13)	0.60 (8.47)	0.83 (0.16)	0.87 (0.12)	1.80 (22.58)	0.75 (0.24)
CHIRPS	0.82 (0.15)	3.80 (15.26)	0.74 (0.20)	0.81 (0.15)	5.85 (23.59)	0.68 (0.28)
ERA5	0.74 (0.16)	−9.35 (29.36)	0.54 (0.27)	0.74 (0.15)	−3.90 (32.00)	0.55 (0.31)
GLDAS	0.74 (0.16)	11.90 (34.02)	0.60 (0.34)	0.71 (0.17)	15.95 (37.91)	0.52 (0.38)
IMERG	0.78 (0.15)	16.40 (26.99)	0.62 (0.34)	0.77 (0.15)	19.35 (31.98)	0.54 (0.45)
MERRA-2	0.82 (0.15)	−9.25 (18.09)	0.65 (0.21)	0.78 (0.15)	−19.35 (36.90)	0.50 (0.32)
PERSIANN-CDR	0.74 (0.16)	17.55 (33.83)	0.56 (0.34)	0.72 (0.16)	20.95 (37.08)	0.51 (0.56)
TRMM	0.77 (0.16)	18.80 (25.60)	0.58 (0.32)	0.76 (0.15)	24.55 (32.07)	0.50 (0.41)

Table 4 shows the hydrological model performance by calibrating the individual models with a given precipitation product. The results showed that compared with calibration approach I, the hydrologic performance of all products has improved (Table 4). The median r for the CHIRPS product presented the highest value for both calibration (0.84) and validation (0.83) periods, followed by the IMERG and TRMM products, which presented a r value of 0.81 for the calibration phase and 0.80 for validation (Table 4). The standard deviation of pbias values increased in the validation period for all products, and the satellite products generally overestimated the flow with median values higher than 0. In the calibration phase, the best pbias median values were provided by ERA5 (0.7 %) and TRMM (0.3 %), whereas in the

Table 4

Median and standard deviation (values shown in brackets) of statistical metrics for discharge simulation for all 714 selected catchments using calibration approach II.

Precipitation product	Calibration			Validation		
	r [0–1]	pbias (%) [−∞–∞]	KGE [−∞–1]	r [0–1]	pbias (%) [−∞–∞]	KGE [−∞–1]
CHIRPS	0.84 (0.14)	1.35 (8.39)	0.77 (0.18)	0.83 (0.14)	3.25 (25.58)	0.71 (0.37)
ERA5	0.76 (0.15)	0.70 (8.40)	0.66 (0.19)	0.75 (0.15)	4.65 (32.15)	0.60 (0.40)
GLDAS	0.76 (0.15)	0.30 (9.57)	0.68 (0.19)	0.73 (0.16)	4.95 (27.14)	0.61 (0.28)
IMERG	0.81 (0.14)	0.45 (8.93)	0.75 (0.18)	0.80 (0.14)	4.30 (23.36)	0.66 (0.30)
MERRA-2	0.84 (0.14)	1.10 (9.22)	0.76 (0.18)	0.79 (0.15)	−9.40 (31.47)	0.59 (0.30)
PERSIANN-CDR	0.77 (0.15)	1.10 (8.92)	0.68 (0.19)	0.73 (0.16)	4.80 (26.79)	0.61 (0.47)
TRMM	0.81 (0.14)	0.30 (8.46)	0.74 (0.18)	0.80 (0.14)	6.30 (26.81)	0.65 (0.34)

validation phase, the best values were CHIRPS (3.25 %) and IMERG (4.3 %). The median KGE values show better results for CHIRPS, IMERG, and TRMM, in this order, with median KGE values above 0.64 for both the calibration and validation phases.

All products showed pbias values of average daily river flow close to zero in calibration and a tendency of overestimation for the validation period, with the exception of MERRA-2 and the northeast region, especially for the Sao Francisco river basin (Fig. 7). The metrics r and KGE showed the worst performances for some of the catchments located in the South and Northeast regions. The values of r for the average daily river flow show good performance for the majority of the Brazilian catchments, with r values > 0.6 for 85.6 % of the catchments for all precipitation products using approach II (78.9 % of the catchments showed $r > 0.6$ using approach I in the calibration phase). Regarding




Fig. 7. Performance metrics r , pbias, and KGE for the seven different precipitation products in the simulation of daily river flow in the Brazilian basins.

KGE, all products performed well for most catchments in the calibration phase. For instance, the mean KGE values are higher than 0.5 for 78.0 % (approach II) and 57.3 % (approach I) of the simulated catchments with ERA5; 89.6 % (approach II) and 69.0 % (approach I) for IMERG; 91.3 and 87.1% for CHIRPS in the approaches II and I, respectively. The lowest KGE values were recorded in some of Brazil's southern and northeastern catchments. The results also showed that there is no consistent improvement in the hydrological model performance of the different precipitation products as the catchment area increases (Fig. S3B), unlike precipitation performance (Fig. S3A).

The diagram relating the KGE and pbias performance of the twelve hydrographic regions of Brazil and the ground-based rainfall and precipitation products is presented in Fig. 8. The Western Northeast Atlantic hydrographic region showed pbias below -6.55% and KGE value above 0.72 for all precipitation products. In contrast, the East Atlantic hydrographic region overestimated flow values with pbias values above 1.95% for all precipitation products. The highest KGE values (>0.76) were recorded for the Amazon, Tocantins-Araguaia, and Paraguay hydrographic regions for all precipitation products. These regions are mainly affected by floodplain interactions and consequent attenuation of flood peaks (Lininger and Latrubesse, 2016). On the other hand, the lowest KGE values (<0.62) were recorded in the most arid hydrographic regions (Eastern NE Atlan. and East Atlan.) and South Atlan.

As expected, the models using ground-based precipitation performed better in the calibration period than the precipitation products (Fig. 9A and B) for approximately 60 % of the catchments. Overall, the runoff estimates using the precipitation products were satisfactory, with CHIRPS and MERRA-2 exhibiting the best KGE performance for 36.3 % and 13.4 % of the catchments, respectively, when compared with the satellite and reanalysis-based precipitation products (Fig. 9B).

4.3. Sensitivity of GR4J model parameters

The results of the sensitivity of the model parameters (Fig. 10) shows that the parameters related to soil moisture accounting store (X1) and groundwater exchange (X2) exhibit higher sensitivity for most datasets, while the unit hydrograph parameter (X4) is the least sensitive for most precipitation datasets ($TSI < 0.2$) (Fig. 10). The ground-based rainfall data showed higher sensitivity of the parameters than other precipitation products; moreover, this result indicates that the sensitivity of the model parameters can change according to the input data set. Additionally, our results show that the sensitivity changes according to the climate and aridity of the catchment; for example X1 is more sensitive in regions of greater aridity, whereas X2 is more sensitive in regions with higher humidity (Fig. S5).

5. Discussion

5.1. Catchment-averaged precipitation performance

Overall, the precipitation datasets showed a tendency to overestimate, with the exception of ERA5 and MERRA-2 when compared with ground-based precipitation. Moreover, the performance of the precipitation products changes depending on the hydrographic region, Brazil's driest and wettest catchments had the poorest performance. These findings reinforce the result of Andrade et al. (2022), which suggests that the performance of satellite and reanalysis products depends on the characteristics of each climate and rainfall system that occurs in a given region. Jiang and Bauer-Gottwein (2019) indicated that satellite-based precipitation products in Mainland China tend to consistently underestimate in tropical zones and conversely overestimate in arid zones. The precipitation for the catchments located near




Fig. 8. Diagram of the twelve hydrographic regions in descending order by aridity index of Brazil for the ground-based (GB) rainfall and the seven products to calibration phase. The size of each circle indicates the median KGE value of the catchments located in a given hydrographic region and a given precipitation product. The colour of each circle indicates the median pbias value.




Fig. 9. Best values of KGE for the calibration period. A) All precipitation products including ground-based rainfall. B) All precipitation products excluding ground-based rainfall.




Fig. 10. Boxplot of the Sobol Total Sensitivity Indices (TSI) for the GR4J parameters for the 714 basins analyzed.

the coast of Northeastern and Southeastern Brazil have a greater tendency to underestimate precipitation; this can be explained in part by the presence of warm-rain precipitation, which is more difficult to measure by infrared satellite sensors (Gadelha et al., 2019; Althoff et al., 2021; Andrade et al., 2022). The cloud-tops have little vertical development and low ice content and would be too warm for the infrared thresholds to be detected by these sensors (Mitra et al., 2018; Derin et al., 2022). Our results confirm that a consistent performance improvement of the precipitation products is observed as the river basin area increases (Fig. S4A); the study by Duan et al. (2016) indicates that assessment metrics improve as the spatial scale increases from grid to catchment. Our results are consistent with those results by Zhao et al. (2020) and Guo et al. (2023), who showed that the performance of precipitation datasets improves as spatial scale becomes larger.

5.2. Hydrological model performance

We assessed the different precipitation products when the hydrological models were calibrated based on the ground-based rainfall (approach I). The hydrological models exhibited a decrease in

performance when evaluated with reanalysis precipitation products for the calibration and validation periods (Table 3). This can be explained by the errors observed in some of the precipitation products. Another reason for this behaviour is that the parameters calibrated by the rain gauge observations are not optimal for the precipitation products (Su et al., 2021). The hydrological simulations with recalibration for each precipitation product (Approach II) improved the simulation of river discharges. Our results are consistent with several studies (Zeng et al., 2018; Su et al., 2021; Khatakho et al., 2021) that concluded that hydrological simulation efficiency is enhanced by input-specific recalibration. This can be explained by the ability of the GR4J model to dampen errors and biases in the precipitation inputs through specific parameterisation of the precipitation products, as shown in Figure S4, often allowing reasonable flow prediction even with substantial input errors (Stephens et al., 2022). However, the model parameters calibrated based on the biased precipitation inputs, such as satellite-based precipitation products or reanalysis, may not be sufficient to characterise the hydrological simulation in the basin, and calibration parameters may have inadequate ranges (Su et al., 2019; Su et al., 2021). Furthermore, the GR4J model is subjected to equifinality, and systematic changes in parameters based on physical processes do not necessarily improve performance (Stephens et al., 2019). Using a single objective function, the model performance had KGE values greater than 0.5 for both calibration and validation periods for 83.05 % catchments when using ground-based precipitation. The use of multi-optimization and multi-objective techniques applied by Adeyeri et al. (2020) for model calibration is something to explore in future work. These authors advocate that the phenomena of equifinality, posed by Beven (2002) as a range of potentially acceptable models, can be reduced by improving the estimation of parameter values.

The hydrological models driven by CHIRPS, MERRA-2, and IMERG showed optimal performance metrics in most catchments ($KGE > 0.81$) during calibration, except for the semi-arid regions. An explanation for the low performance of the semi-arid region could be a large number of reservoirs in the northeast region of Brazil, which is not considered by the hydrological model used in this study, in addition to the poor

performance of precipitation products in this region (Almagro et al., 2021b). Besides the higher proportion of low flows and their intermittence compared to wet basins can make hydrological model calibration more challenging (Messenger et al., 2021). The study by Jiang and Bauer-Gottwein (2019) also found lower performance in arid regions in China using TRMM and IMERG.

The models driven by IMERG showed slightly better hydrological performance than those models driven by TRMM; this aligns with findings from prior research (Jiang and Bauer-Gottwein, 2019; Zhao et al., 2020). In addition, our study showed that the higher-quality precipitation products produced a better hydrological response, which is the case of CHIRPS, MERRA-2 and IMERG; however, in the case of TRMM, this relationship was not straightforward; a plausible explanation for this is that errors in precipitation products are better compensated via hydrological modelling in wet regions (Fig. S2). This is more evident for the TRMM because this product exhibited one of the worst precipitation performances in wet regions (Fig. 5), whereas the results of its hydrological simulation were improved (Fig. 7). Furthermore, other studies indicate that the quality of precipitation products and the hydrological response may not be directly linked (Qi et al., 2016; Jiang and Bauer-Gottwein, 2019; Camici et al., 2020). Moreover, no consistent improvement was found in the performance of the hydrological models driven by precipitation products as the catchment area increases unlike precipitation performance, also verified in other studies (Almagro et al., 2022, Jiang and Bauer-Gottwein, 2019).

The poor model performance as shown by KGE in the South Atlantic hydrographic region can be due to the absence of a well-defined precipitation seasonality (Fig. 1) (Siqueira et al., 2018; Almagro et al., 2021b). In addition, in some regions, precipitation products can perform better than ground-based precipitation, which can be helpful since the density of rainfall stations is relatively sparse in Brazil, especially in the Amazon and Pantanal regions and in some areas of the Brazilian Northeast (Gadelha et al., 2019). Due to the limited monitoring station availability, Tarek et al. (2020) found that ERA5-based hydrological simulations outperformed observed precipitation-based simulations in the US and Canadian mountain basins. This highlights reanalysis and satellite data as alternatives for observations in data-sparse regions.

5.3. Sensitivity analysis

Our results showed that the parameters' sensitivity changes according to the input data set, climate and aridity of the catchment. The X2 parameter shows higher sensitivity for most dataset, similar results were found in the study of Wanzala et al. (2022) in 19 flood-prone catchments in Kenya, Eastern Africa. The sensitivity depends on the length of the data period, parameter ranges, physical characteristics of the catchments, model structures, and climatic conditions, indicating that care must be taken when making generalisations or applying them to new situations (Shin et al., 2013; Arheimer et al., 2020). The study by Wang et al. (2023) with twenty-eight multisource rainfall products for a watershed in the southern United States demonstrates that a lumped hydrological model can adapt to some imprecise precipitation inputs up to a specific limit. Moreover, some of our study catchments may be affected by occasional high-intensity rainfall that can create runoff even if the soil is dry (Santos et al., 2022).

In catchments located in regions of greater aridity, the parameter soil moisture accounting store (X1) is more sensitive than the other parameters. The hydrographic regions with higher humidity are more sensitive to the parameter X2. In humid climates, a more significant fraction of precipitation recharges groundwater, while this recharge fraction decreases in drier climates (Berghuijs et al., 2022); this explains the lower sensitivity of the X2 parameter compared to the parameter X1 in arid catchments. The arid catchments have a minimal or no baseflow contribution, most of the river discharge is generated from direct surface runoff, which is largely influenced by the soil's infiltration capacity (Cantoni et al., 2022), which may explain the sensitivity of the

parameter X1.

6 Conclusions

In the present study, we evaluated the accuracy of precipitation, hydrological model performance and parameter sensitivity related to seven precipitation data sets based on satellite and reanalysis products over 714 contrasting tropical and subtropical catchments located in Brazil. The ERA5 and MERRA-2 are the only products that produces underestimate precipitation estimates for most catchments. The findings highlight discrepancies in hydrological model performance between the different precipitation datasets in different catchments with regard to climatic regions and aridity. The precipitation products CHIRPS, IMERG, and MERRA-2 showed the best accuracy in terms of both, precipitation estimation and hydrological simulation performance; moreover, the errors in precipitation products are better compensated via hydrological modelling in wet regions. The study also provides some findings about the sensitivity analysis in tropical and subtropical catchments, where the model parameter sensitivity varies according to precipitation input, climate, and catchment aridity; the groundwater exchange coefficient (X2) was highly sensitive in most catchments, except for the drier ones, which were more responsive to the parameter linked to soil moisture (X1).

Rainfall-runoff modelling plays an important role in hydrology and water resources management, especially in regions with a lack of hydrometeorological data. Our findings help to improve the understanding of the catchment response in tropical and subtropical regions and the reliability of the precipitation products for streamflow simulation. We demonstrated the usefulness of the precipitation datasets as potential alternatives for hydrological applications in tropical and subtropical river basins. Especially in regions with a relatively sparse density of precipitation stations, these products can assist meteorological studies, climate change assessment and water and disaster management. However, the uncertainty associated with a given precipitation dataset needs to be taken into account, considering that precipitation is one of the key factors that influence the rainfall-runoff simulation.

More efforts are needed to better explore the impact of catchment characteristics on the performance of precipitation products in hydrological modelling. The limitation of the streamflow data timeframe does not compromise the analysis and the overall conclusions of this study. However, it is recommended that future studies, when possible, use longer time series to reinforce the robustness of the study. Data-driven models for streamflow simulation could be used to better assess human influence, such as the presence of dams and reservoirs in the catchment. Moreover, future work could focus on evaluating the sub-daily flow performance and flood events using precipitation datasets based on satellite and reanalysis products.

CRedit authorship contribution statement

João M. Andrade: Writing – review & editing, Writing – original draft, Visualization, Validation, Software, Methodology, Investigation, Conceptualization. **Alfredo Ribeiro Neto:** Writing – review & editing, Writing – original draft, Visualization, Supervision, Methodology, Investigation, Conceptualization. **Rodolfo L.B. Nóbrega:** Writing – review & editing, Writing – original draft, Visualization, Supervision, Methodology, Investigation, Conceptualization. **Miguel A. Rico-Ramírez:** Writing – review & editing. **Suzana M.G.L. Montenegro:** Writing – review & editing, Supervision, Formal analysis.

Declaration of competing interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Data availability

CABra datasets are available at <https://doi.org/10.5281/zenodo.4070146> (Almagro et al., 2021a). The ground-based rainfall and evapotranspiration data are available at <http://careyking.com/data-downloads/> (Xavier et al., 2016). The precipitation products, CHIRPS, ERA5, IMERG, GLDAS, MERRA-2, PERSIANN-CDR and TRMM are available through the GEE platform at <https://earthengine.google.com/>.

Acknowledgements

We thank the four anonymous reviewers for their helpful and supportive comments and suggestions. JMA acknowledges the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brazil (CAPES) for a PhD fellowship (Finance Code 001) and the PRINT-CAPES program for the sandwich doctoral scholarship at the University of Bristol – UK. This study was also financed in part by the National Council for Scientific and Technological Development (CNPq), grant numbers 441951/2020-1 and 313392/2020-0, the second and fifth authors thank to CNPq Productivity in Research (PQ); Universal MCTIC/CNPq grant number 431980/2018-7 and project CNPq/MCTIC/BRICS-STI N° 29/2017 grant number 442335/2017-2. For the purpose of open access, the authors have applied a Creative Commons Attribution (CC BY) license to this publication.

Appendix A. Supplementary data

Supplementary data to this article can be found online at <https://doi.org/10.1016/j.jhydrol.2024.131016>.

References

- Adeyeri, O., Laux, P., Arnault, J., Lawin, A., Kunstmann, H., 2020. Conceptual hydrological model calibration using multi objective optimization techniques over the transboundary komadugu-Yobe basin, Lake Chad area, West Africa. *J. Hydrol. Reg. Stud.* 27, 100655 <https://doi.org/10.1016/j.ejrh.2019.100655>.
- Allen, R.G., Pereira, L.S., Raes, D., Smith, M., 1998. Crop evapotranspiration guidelines for computing crop water requirements-FAO irrigation and drainage paper 56. *Fao, Rome* 300 (9), D05109.
- Almagro, A., Oliveira, P.T.S., Meira Neto, A.A., Roy, T., Troch, P., 2021a. CABra: a novel large-sample dataset for Brazilian catchments. *Hydrol. Earth Syst. Sci.* 25 (6), 3105–3135. <https://doi.org/10.5194/hess-25-3105-2021>.
- Almagro, A., Oliveira, P.T.S., Brocca, L., 2021b. Assessment of bottom-up satellite products on estimating river discharge and hydrologic signatures in Brazilian catchments. *J. Hydrol.* 603, 126897. <https://doi.org/10.1016/j.jhydrol.2021.126897>.
- Althoff, D., 2021. Evaluating the latest IMERG products in a subtropical climate: the case of Paraná state. *Brazil. Remote Sensing* 13 (5), 906. <https://doi.org/10.3390/rs13050906>.
- Alvares, C.A., Stape, J.L., Sentelhas, P.C., Gonçalves, J.D.M., Sparovek, G., 2013. Köppen's climate classification map for Brazil. *Meteorol. Z.* 22 (6), 711–728. <https://doi.org/10.1127/0941-2948/2013/0507>.
- Andrade, J.M., Neto, A.R., Bezerra, U.A., Moraes, A.C., Montenegro, S.M., 2022. A comprehensive assessment of precipitation products: temporal and spatial analyses over terrestrial biomes in northeastern Brazil. *Remote Sens. Appl.: Soc. Environ.* 100842 <https://doi.org/10.1016/j.rsase.2022.100842>.
- Arheimer, B., Pimentel, R., Isberg, K., Crochemore, L., Andersson, J.C., Hasan, A., Pineda, L., 2020. Global catchment modelling using world wide HYPE (WWH), open data, and stepwise parameter estimation. *Hydrol. Earth Syst. Sci.* 24 (2), 535–559. <https://doi.org/10.5194/hess-24-535-2020>.
- Arora, V.K., 2002. O uso do índice de aridez Para avaliar o efeito das mudanças climáticas no escoamento anual. *J. Hydrol.* 265 (1–4), 164–177. [https://doi.org/10.1016/S0022-1694\(02\)00101-4](https://doi.org/10.1016/S0022-1694(02)00101-4).
- Ashouri, H., Hsu, K.L., Sorooshian, S., Braithwaite, D.K., Knapp, K.R., Cecil, L.D., Prat, O. P., 2015. PERSIANN-CDR: daily precipitation climate data record from multisatellite observations for hydrological and climate studies. *Bull. Am. Meteorol. Soc.* 96 (1), 69–83. <https://doi.org/10.1175/BAMS-D-13-00068.1>.
- Baethgen, W.E., & Goddard, I. (2013). Latin American perspectives on adaptation of agricultural systems to climate variability and change. In *Handbook of Climate Change and Agroecosystems: Global and Regional Aspects and Implications—Joint Publication with the American Society of Agronomy, Crop Science Society of America, and Soil Science Society of America* (pp. 57–72).
- Beaudoin, H., Rodell, M., 2020. GLDAS Noah land surface model L4 3 hourly 0.25 x 0.25 degree V2.1. In: *Earth Sciences Data and Information Services Center (GES DISC). NASA/GSFC/HSI, Greenbelt, Maryland, USA*. <https://doi.org/10.5067/E7TYRXPJKWOQ>.
- Beck, H.E., Vergopolan, N., Pan, M., Levizzani, V., Van Dijk, A.I., Weedon, G.P., ... & Wood, E.F. (2017). Global-scale evaluation of 22 precipitation datasets using gauge observations and hydrological modeling. *Hydrology and Earth System Sciences*, 21 (12), 6201–6217. <https://doi.org/10.5194/hess-21-6201-2017>, 2017.
- Berghuijs, W.R., Luijendijk, E., Moerk, C., Allen, S.T., 2022. Global recharge data set indicates strengthened groundwater connection to surface fluxes. *e2022GL099010* *Geophys. Res. Lett.* 49 (23). <https://doi.org/10.1029/2022GL099010>.
- Beven, K., 2002. Towards an alternative blueprint for a physically based digitally simulated hydrologic response modelling system. *Hydrol. Process.* 16 (2), 189–206. <https://doi.org/10.1002/hyp.343>.
- Brighton, T.M., Bonumá, N.B., Grison, F., de Almeida Mota, A., Kobiyama, M., Chaffe, P. L.B., 2019. Two calibration methods for modeling streamflow and suspended sediment with the swat model. *Ecol. Eng.* 127, 103–113. <https://doi.org/10.1016/j.ecoleng.2018.11.007>.
- Brocca, L., Massari, C., Pellarin, T., Filippucci, P., Ciabatta, L., Camici, S., Fernández-Prieto, D., 2020. River flow prediction in data scarce regions: soil moisture integrated satellite rainfall products outperform rain gauge observations in West Africa. *Sci. Rep.* 10 (1) <https://doi.org/10.1038/s41598-020-69343-x>.
- Bytheway, J.L., Kummerow, C.D., 2010. A physically based screen for precipitation over complex surfaces using passive microwave observations. *IEEE Trans. Geosci. Remote Sens.* 48 (1), 299–313. <https://doi.org/10.1109/tgrs.2009.2027434>.
- Camici, S., Ciabatta, L., Massari, C., Brocca, L., 2018. How reliable are satellite precipitation estimates for driving hydrological models: a verification study over the Mediterranean area. *J. Hydrol.* 563, 950–961. <https://doi.org/10.1016/j.jhydrol.2018.06.067>.
- Camici, S., Massari, C., Ciabatta, L., Marchesini, I., Brocca, L., 2020. Which rainfall score is more informative about the performance in river discharge simulation? a comprehensive assessment on 1318 basins over Europe. *Hydrol. Earth Syst. Sci.* 24 (10), 4869–4885. <https://doi.org/10.5194/hess-24-4869-2020>.
- Cantoni, E., Trambly, Y., Grimaldi, S., Salamon, P., Dakhlaoui, H., Dezetter, A., Thiémi, V., 2022. Hydrological performance of the ERA5 reanalysis for flood modeling in Tunisia with the LISFLOOD and GR4J models. *J. Hydrol.: Reg. Stud.* 42, 101169 <https://doi.org/10.1016/j.ejrh.2022.101169>.
- Cavalcante, R.B.L., Ferreira, D.B.D.S., Pontes, P.R.M., Tedeschi, R.G., Da Costa, C.P.W., De Souza, E.B., 2020. Evaluation of extreme rainfall indices from CHIRPS precipitation estimates over the Brazilian Amazonia. *Atmos. Res.* 238, 104879 <https://doi.org/10.1016/j.atmosres.2020.104879>.
- Chagas, V.B., Chaffe, P.L., Addor, N., Fan, F.M., Fleischmann, A.S., Paiva, R.C., & Siqueira, V.A. (2020). CAMELS-BR: Hydrometeorological time series and landscape attributes for 897 catchments in Brazil. *Earth System Science Data*, 12(3), 2075–2096. <https://doi.org/10.5194/essd-12-2075-2020>, 2020.
- Coron, L., Perrin, C., Delaigue, O., Thirel, G. and Michel, C. (2018). airGR: Suite of GR Hydrological Models for Precipitation Runoff Modelling. R package version 1.0.10.11. URL: <https://webgr.iirstea.fr/en/airGR/>.
- Coron, L., Thirel, G., Delaigue, O., Perrin, C., Andressian, V., 2017. The suite of lumped GR hydrological models in an R package. *Environ. Model. Softw.* 94, 166–171. <https://doi.org/10.1016/j.envsoft.2017.05.002>.
- Dembélé, M., Zwart, S.J., 2016. Evaluation and comparison of satellite-based rainfall products in Burkina Faso, West Africa. *Int. J. Remote Sens.* 37 (17), 3995–4014. <https://doi.org/10.1080/01431161.2016.1207258>.
- Derin, Y., Kirstetter, P.E., Brauer, N., Gourley, J.J., Wang, J., 2022. Evaluation of IMERG satellite precipitation over the land-coast-ocean continuum. Part II: Quantification. *Journal of Hydrometeorology* 23 (8), 1297–1314. <https://doi.org/10.1175/JHM-D-21-0234.1>.
- Duan, Z., Liu, J., Tuo, Y., Chiogna, G., Disse, M., 2016. Evaluation of eight high spatial resolution gridded precipitation products in Adige Basin (Italy) at multiple temporal and spatial scales. *Sci. Total Environ.* 573, 1536–1553. <https://doi.org/10.1016/j.scitotenv.2016.08.213>.
- Dube, S., Gupta, H., Goyal, M.K., Joshi, N., 2021. Evaluation of precipitation datasets available on Google earth engine over India. *Int. J. Climatol.* 41 (10), 4844–4863. <https://doi.org/10.1002/joc.7102>.
- Falck, A.S., Maggioni, V., Tomasella, J., Vila, D.A., Diniz, F.L., 2015. Propagation of satellite precipitation uncertainties through a distributed hydrologic model: a case study in the Tocantins-araguaia basin in Brazil. *J. Hydrol.* 527, 943–957. <https://doi.org/10.1016/j.jhydrol.2015.05.042>.
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., Michaelsen, J., 2015. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Sci. Data* 2 (1), 1–21. <https://doi.org/10.1038/sdata.2015.66>.
- Gadella, A.N., Coelho, V.H.R., Xavier, A.C., Barbosa, L.R., Melo, D.C., Xuan, Y., Huffman, G.J., Petersen, W.A., Almeida, C.D.N., 2019. Grid box-level evaluation of IMERG over Brazil at various space and time scales. *Atmos. Res.* 218, 231–244. <https://doi.org/10.1016/j.atmosres.2018.12.001>.
- Gelaro, R., McCarty, W., Suárez, M.J., Todling, R., Molod, A., Takacs, L., Zhao, B., 2017. The modern-era retrospective analysis for research and applications, version 2 (MERRA-2). *J. Clim.* 30 (14), 5419–5454. <https://doi.org/10.1175/JCLI-D-16-0758.1>.
- Getirana, A., 2016. Extreme water deficit in Brazil detected from space. *J. Hydrometeorol.* 17 (2), 591–599. <https://doi.org/10.1175/JHM-D-15-0096.1>.
- Getirana, A., Libonati, R., Cataldi, M., 2021. Brazil is in water crisis—it needs a drought plan. *Nature* 600 (7888), 218–220. <https://doi.org/10.1038/d41586-021-03625-w>.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R., 2017. Google earth engine: planetary-scale geospatial analysis for everyone. *Remote Sens. Environ.* 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>.
- Guo, B., Xu, T., Yang, Q., Zhang, J., Dai, Z., Deng, Y., Zou, J., 2023. Multiple spatial and temporal scales evaluation of eight satellite precipitation products in a mountainous

- catchment of South China. *Remote Sens. (Basel)* 15 (5), 1373. <https://doi.org/10.3390/rs15051373>.
- Gupta, H.V., Kling, H., Yilmaz, K.K., Martinez, G.F., 2009. Decomposition of the mean squared error and NSE performance criteria: implications for improving hydrological modelling. *J. Hydrol.* 377 (1–2), 80–91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>.
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz Sabater, J., Thépaut, J.N., 2020. The ERA5 global reanalysis. *Q. J. R. Meteorol. Soc.* 146 (730), 1999–2049. <https://doi.org/10.1002/qj.4174>.
- Huffman, G. J., Bolvin, D. T., Nelkin, E. J., Wolff, D. B., Adler, R. F., Gu, G., ... & Stocker, E. F. (2007). The TRMM multisatellite precipitation analysis (TMPA): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. *Journal of hydrometeorology*, 8(1), 38–55. <https://doi.org/10.1175/JHM560.1>.
- Huffman, G. J., Stocker, E. F., Bolvin, D. T., Nelkin, E. J., & Tan, J. (2019). GPM IMERG final precipitation L3 half hourly 0.1 degree x 0.1 degree V06. Greenbelt, MD, Goddard Earth Sciences Data and Information Services Center (GES DISC). Accessed date: 17 September 2021, doi:10.5067/GPM/IMERG/3B-HH/06.
- Iooss, B., Janon, A., Pujol, G., Broto, B., Bounhaout, K., Da Veiga, S., Guillaume, J., 2021. Sensitivity: global sensitivity analysis of model outputs. R Package Version 1.
- Jiang, L., Bauer-Gottwein, P., 2019. How do GPM IMERG precipitation estimates perform as hydrological model forcing? evaluation for 300 catchments across mainland China. *J. Hydrol.* 572, 486–500. <https://doi.org/10.1016/j.jhydrol.2019.03.042>.
- Junqueira, R., Viola, M.R., Amorim, J.D.S., Camargos, C., De Mello, C.R., 2022. Hydrological modeling using remote sensing precipitation data in a Brazilian savanna basin. *J. S. Am. Earth Sci.* 115, 103773 <https://doi.org/10.1016/j.jsames.2022.103773>.
- Khatakho, R., Talchabhadel, R., Thapa, B.R., 2021. Evaluation of different precipitation inputs on streamflow simulation in Himalayan River basin. *J. Hydrol.* 599, 126390. <https://doi.org/10.1016/j.jhydrol.2021.126390>.
- Kidd, C., Huffman, G., 2011. Global precipitation measurement. *Meteorol. Appl.* 18 (3), 334–353. <https://doi.org/10.1002/met.284>.
- Kirschbaum, D.B., Huffman, G.J., Adler, R.F., Braun, S., Garrett, K., Jones, E., Zaitchik, B. F., 2017. NASA's remotely sensed precipitation: a reservoir for applications users. *Bull. Am. Meteorol. Soc.* 98 (6), 1169–1184. <https://doi.org/10.1175/BAMS-D-15-00296.1>.
- Knoben, W.J., Freer, J.E., Woods, R.A., 2019. Inherent benchmark or not? comparing Nash Sutcliffe and Kling Gupta efficiency scores. *Hydrol. Earth Syst. Sci.* 23 (10), 4323–4331. <https://doi.org/10.5194/hess-23-4323-2019>.
- Levis, C., Flores, B.M., Mazzochini, G.G., Manhães, A.P., Campos Silva, J.V., Borges de Amorim, P., Clement, C.R., 2020. Help restore Brazil's governance of globally important ecosystem services. *Nat. Ecol. Evol.* 4 (2), 172–173. <https://doi.org/10.1038/s41559-019-1093-x>.
- Li, X.H., Zhang, Q., Xu, C.Y., 2012. Suitability of the TRMM satellite rainfalls in driving a distributed hydrological model for water balance computations in Xinjiang catchment, poyang lake basin. *J. Hydrol.* 426, 28–38. <https://doi.org/10.1016/j.jhydrol.2012.01.013>.
- Lininger, K.B., Latrubesse, E.M., 2016. Flooding hydrology and peak discharge attenuation along the middle Araguaia River in Central Brazil. *Catena* 143, 90–101. <https://doi.org/10.1016/j.catena.2016.03.043>.
- Maggioni, V., Massari, C., 2018. On the performance of satellite precipitation products in riverine flood modeling: a review. *J. Hydrol.* 558, 214–224. <https://doi.org/10.1016/j.jhydrol.2018.01.039>.
- Maggioni, V., Meyers, P.C., Robinson, M.D., 2016. A review of merged high-resolution satellite precipitation product accuracy during the tropical rainfall measuring Mission (TRMM) era. *J. Hydrometeorol.* 17 (4), 1101–1117. <https://doi.org/10.1175/JHM-D-15-0190.1>.
- Mathevet, T., Michel, C., Andréassian, V., Perrin, C., 2006. A bounded version of the Nash-sutcliffe criterion for better model assessment on large sets of basins. *IAHS Publ.* 307, 211.
- Melo, D.D.C., Xavier, A.C., Bianchi, T., Oliveira, P.T., Scanlon, B.R., Lucas, M.C., Wendland, E., 2015. Performance evaluation of rainfall estimates by TRMM multi-satellite precipitation analysis 3B42V6 and V7 over Brazil. *J. Geophys. Res. Atmos.* 120 (18), 9426–9436. <https://doi.org/10.1002/2015JD023797>.
- Messenger, M.L., Lehner, B., Cockburn, C., Lamouroux, N., Pella, H., Snelder, T., Tockner, K., Trautmann, T., Watt, C., Detry, T., 2021. Global prevalence of non-perennial rivers and streams. *Nature* 594 (7863), 391–397. <https://doi.org/10.1038/s41586-021-03565-5>.
- Michel, C., 1991. Hydrologie appliquée aux petits bassins ruraux. *Hydrology handbook*, Cemagref, Antony, France.
- Mitra, A., Kaushik, N., Kumar Singh, A., Parihar, S., Bhan, S., 2018. Evaluation of INSAT-3D satellite derived precipitation estimates for heavy rainfall events and its validation with gridded GPM (IMERG) rainfall dataset over the Indian region. *Remote Sens. Appl.: Soc. Environ.* 9, 91–99. <https://doi.org/10.1016/j.rsase.2017.12.006>.
- Mizukami, N., Rakovec, O., Newman, A.J., Clark, M.P., Wood, A.W., Gupta, H.V., Kumar, R., 2019. On the choice of calibration metrics for “high-flow” estimation using hydrologic models. *Hydrol. Earth Syst. Sci.* 23 (6), 2601–2614. <https://doi.org/10.5194/hess-23-2601-2019>.
- Moges, D.M., Knoch, A., Uuemaa, E., 2022. Application of satellite and reanalysis precipitation products for hydrological modeling in the data-scarce porijogi catchment. *Estonia. Journal of Hydrology: Regional Studies* 41, 101070. <https://doi.org/10.1016/j.ejrh.2022.101070>.
- Mohammadi, B., Safari, M.J.S., Vazifekhal, S., 2022. IHACRES, GR4J and MISD-based multi conceptual-machine learning approach for rainfall-runoff modeling. *Sci. Rep.* 12 (1), 12096. <https://doi.org/10.1038/s41598-022-16215-1>.
- Mithaa, S., Asano, S., 2022. Hydrological evaluation of radar and satellite gauge-merged precipitation datasets using the SWAT model: case of the terauchi catchment in Japan. *J. Hydrol.: Reg. Stud.* 42, 101134 <https://doi.org/10.1016/j.ejrh.2022.101134>.
- Mu, Y., Biggs, T., Shen, S.S., 2021. Satellite-based precipitation estimates using a dense rain gauge network over the southwestern Brazilian Amazon: implication for identifying trends in dry season rainfall. *Atmos. Res.* 261, 105741 <https://doi.org/10.1016/j.atmosres.2021.105741>.
- Nash, J.E., Sutcliffe, J.V., 1970. River flow forecasting through conceptual models part I — a discussion of principles. *J. Hydrol.* 10 (3), 282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6).
- Nayak, A.K., Biswal, B., Sudheer, K.P., 2021. Role of hydrological model structure in the assimilation of soil moisture for streamflow prediction. *J. Hydrol.* 598, 126465. <https://doi.org/10.1016/j.jhydrol.2021.126465>.
- Oliveira-Junior, S., Teodoro, P. E., Rossi, F. S., Cavalcante Blanco, C. J., Lima, M., Félix Correia Filho, W. L., Santiago, B., & Vanderley, S. (2021). Confronting CHIRPS dataset and in situ stations in the detection of wet and drought conditions in the Brazilian Midwest. *International Journal of Climatology*, 41(9), 4478–4493. <https://doi.org/10.1002/joc.7080>.
- Paredes-Trejo, F.J., Barbosa, H.A., Kumar, T.L., 2017. Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil. *J. Arid Environ.* 139, 26–40. <https://doi.org/10.1016/j.jaridenv.2016.12.009>.
- Perrin, C., Michel, C., Andréassian, V., 2003. Improvement of a parsimonious model for streamflow simulation. *J. Hydrol.* 279 (1–4), 275–289. [https://doi.org/10.1016/S0022-1694\(03\)00225-7](https://doi.org/10.1016/S0022-1694(03)00225-7).
- Qi, W., Zhang, C., Fu, G., Sweetapple, C., Zhou, H., 2016. Evaluation of global fine-resolution precipitation products and their uncertainty quantification in ensemble discharge simulations. *Hydrol. Earth Syst. Sci.* 20 (2), 903–920. <https://doi.org/10.5194/hess-20-903-2016>.
- R Development Core Team, 2015. R: a language and environment for statistical computing. Vienna, Austria, R Foundation for Statistical Computing <http://www.R-project.org/>.
- Ramos Filho, G.M., Coelho, V.H.R., da Silva Freitas, E., Xuan, Y., Brocca, L., das Neves Almeida, C., 2022. Regional-scale evaluation of 14 satellite-based precipitation products in characterising extreme events and delineating rainfall thresholds for flood hazards. *Atmos. Res.* 276, 106259 <https://doi.org/10.1016/j.atmosres.2022.106259>.
- Reichle, R.H., Liu, Q., Koster, R.D., Draper, C.S., Mahanama, S.P., Partyka, G.S., 2017. Land surface precipitation in MERRA-2. *J. Clim.* 30 (5), 1643–1664. <https://doi.org/10.1175/JCLI-D-16-0570.1>.
- Reis, A.A.D., Weerts, A., Ramos, M., Wetterhall, F., Fernandes, W.D.S., 2022. Hydrological data and modeling to combine and validate precipitation datasets relevant to hydrological applications. *J. Hydrol.: Reg. Stud.* 44, 101200 <https://doi.org/10.1016/j.ejrh.2022.101200>.
- Rodell, M., Houser, P.R., Jambor, U.E.A., Gottschalk, J., Mitchell, K., Meng, C.J., Toll, D., 2004. The global land data assimilation system. *Bull. Am. Meteorol. Soc.* 85 (3), 381–394. <https://doi.org/10.1175/BAMS-85-3-381>.
- Satelli, A., 2002. Making best use of model evaluations to compute sensitivity indices. *Comput. Phys. Commun.* 145 (2), 280–297. [https://doi.org/10.1016/S0010-4655\(02\)00280-1](https://doi.org/10.1016/S0010-4655(02)00280-1).
- Santos, L., Andersson, J.C., Arheimer, B., 2022. Evaluation of parameter sensitivity of a rainfall runoff model over a global catchment set. *Hydrol. Sci. J.* 67 (3), 342–357. <https://doi.org/10.1080/02626667.2022.2035388>.
- Satge, F., Pillot, B., Roig, H., Bonnet, M., 2021. Are gridded precipitation datasets a good option for streamflow simulation across the Juruá river basin, Amazon? *J. Hydrol.* 602, 126773 <https://doi.org/10.1016/j.jhydrol.2021.126773>.
- Schönfelder, L. H., Bakken, T. H., Alfrædsen, K., and Adera, A. G.: Application of HYPE in Norway, Assessment of the hydrological model HYPE as a tool to support the implementation of EU Water Framework Directive in Norway, SINTEF Energy Research, report no. 2017:00737, available at: <https://sintef.brage.unit.no/sintef-xnlui/handle/11250/2499427> (last access: 22 February 2022), 2017.
- Shin, M.J., Guillaume, J.H., Croke, B.F., Jakeman, A.J., 2013. Addressing ten questions about conceptual rainfall-runoff models with global sensitivity analyses in R. *J. Hydrol.* 503, 135–152. <https://doi.org/10.1016/j.jhydrol.2013.08.047>.
- Shin, M., Jung, Y., 2022. Using a global sensitivity analysis to estimate the appropriate length of calibration period in the presence of high hydrological model uncertainty. *J. Hydrol.* 607, 127546 <https://doi.org/10.1016/j.jhydrol.2022.127546>.
- Siqueira, V.A., Paiva, R.C., Fleischmann, A.S., Fan, F.M., Ruhoff, A.L., Pontes, P.R., Collischonn, W., 2018. Toward continental hydrologic-hydrodynamic modeling in South America. *Hydrol. Earth Syst. Sci.* 22 (9), 4815–4842. <https://doi.org/10.5194/hess-22-4815-2018>.
- Sobol, I.M., 1993. Sensitivity estimates for nonlinear mathematical models. *Math. Model. Comput. Exp.* 1, 407.
- Stephens, C.M., Marshall, L.A., Johnson, F.M., 2019. Investigating strategies to improve hydrologic model performance in a changing climate. *J. Hydrol.* 579, 124219 <https://doi.org/10.1016/j.jhydrol.2019.124219>.
- Stephens, C.M., Pham, H.T., Marshall, L.A., Johnson, F.M., 2022. Which rainfall errors can hydrologic models handle? implications for using satellite-derived products in sparsely gauged catchments. *Water Resour. Res.* e2020WR029331 <https://doi.org/10.1029/2020WR029331>.
- Su, J., Lü, H., Ryu, D., Zhu, Y., 2019. The assessment and comparison of TMPA and IMERG products over the major basins of mainland China. *Earth Space Sci.* 6 (12), 2461–2479. <https://doi.org/10.1029/2019EA000977>.
- Su, J., Li, X., Ren, W., Lü, H., Zheng, D., 2021. How reliable are the satellite-based precipitation estimations in guiding hydrological modelling in South China? *J. Hydrol.* 602, 126705 <https://doi.org/10.1016/j.jhydrol.2021.126705>.

- Tarek, M., Brissette, F.P., Arsenault, R., 2020. Evaluation of the ERA5 reanalysis as a potential reference dataset for hydrological modelling over North America. *Hydrol. Earth Syst. Sci.* 24 (5), 2527–2544. <https://doi.org/10.5194/hess-24-2527-2020>.
- Tarek, M., Brissette, F., Arsenault, R., 2021. Uncertainty of gridded precipitation and temperature reference datasets in climate change impact studies. *Hydrol. Earth Syst. Sci.* 25 (6), 3331–3350. <https://doi.org/10.5194/hess-25-3331-2021>.
- Teegne, G., Park, D.K., Kim, Y.O., 2017. Comparison of hydrological models for the assessment of water resources in a data-scarce region, the upper Blue Nile River basin. *J. Hydrol.: Reg. Stud.* 14, 49–66. <https://doi.org/10.1016/j.ejrh.2017.10.002>.
- Toté, C., Patricio, D., Boogaard, H., Van der Wijngaart, R., Tarnavsky, E., Funk, C., 2015. Evaluation of satellite rainfall estimates for drought and flood monitoring in Mozambique. *Remote Sens. (Basel)* 7 (2), 1758–1776. <https://doi.org/10.3390/rs70201758>.
- TRMM TROPICAL RAINFALL MEASURING MISSION. PRECIPITATION PROCESSING SYSTEM - File Specification for TRMM Products, 2017. version 7.006. Pp. 983 329. <https://arthurhou.pps.eosdis.nasa.gov/Documents/filespec/TRMM.V7.pdf>. Accessed 984 date: 03 January 2021.
- Villarini, G., Krajewski, W.F., Smith, J.A., 2009. New paradigm for statistical validation of satellite precipitation estimates: application to a large sample of the TMPA 0.25° 3-hourly estimates over Oklahoma. *J. Geophys. Res. Atmos.* 114 (D12) <https://doi.org/10.1029/2008JD011475>.
- Wang, N., Liu, W., Sun, F., Yao, Z., Wang, H., Liu, W., 2020a. Evaluating satellite based and reanalysis precipitation datasets with gauge-observed data and hydrological modeling in the Xihe River basin. *China. Atmospheric Research* 234, 104746. <https://doi.org/10.1016/j.atmosres.2019.104746>.
- Wang, Y., Wang, L., Li, X., Zhou, J., Hu, Z., 2020b. An integration of gauge, satellite, and reanalysis precipitation datasets for the largest river basin of the Tibetan plateau. *Earth Syst. Sci. Data* 12 (3), 1789–1803. <https://doi.org/10.5194/essd-12-1789-2020>.
- Wang, J., Zhuo, L., Han, D., Liu, Y., Rico-Ramirez, M.A., 2023. Hydrological model adaptability to rainfall inputs of varied quality. *e2022WR032484 Water Resour. Res.* 59 (2). <https://doi.org/10.1029/2022WR032484>.
- Wanzala, M.A., Ficchi, A., Cloke, H.L., Stephens, E.M., Badjana, H.M., Lavers, D.A., 2022. Assessment of global reanalysis precipitation for hydrological modelling in data-scarce regions: a case study of Kenya. *J. Hydrol.: Reg. Stud.* 41, 101105 <https://doi.org/10.1016/j.ejrh.2022.101105>.
- Wei, C., Dong, X., Ma, Y., Gou, J., Li, L., Bo, H., Yu, D., Su, B., 2023. Applicability comparison of various precipitation products of long-term hydrological simulations and their impact on parameter sensitivity. *J. Hydrol.* 618, 129187 <https://doi.org/10.1016/j.jhydrol.2023.129187>.
- Wu, Y., Guo, L., Zheng, H., Zhang, B., Li, M., 2019. Hydroclimate assessment of gridded precipitation products for the Tibetan plateau. *Sci. Total Environ.* 660, 1555–1564. <https://doi.org/10.1016/j.scitotenv.2019.01.119>.
- Wu, X., Su, J., Ren, W., Lü, H., Yuan, F., 2023. Statistical comparison and hydrological utility evaluation of ERA5-land and IMERG precipitation products on the Tibetan plateau. *J. Hydrol.* 620, 129384 <https://doi.org/10.1016/j.jhydrol.2023.129384>.
- Xavier, A.C., King, C.W., Scanlon, B.R., 2016. Daily gridded meteorological variables in Brazil (1980–2013). *Int. J. Climatol.* 36 (6), 2644–2659. <https://doi.org/10.1002/joc.4518>.
- Xu, J., Ma, Z., Yan, S., Peng, J., 2022. Do ERA5 and ERA5-land precipitation estimates outperform satellite-based precipitation products? a comprehensive comparison between state of the art model based and satellite based precipitation products over mainland China. *J. Hydrol.* 605, 127353 <https://doi.org/10.1016/j.jhydrol.2021.127353>.
- Yang, Y., Du, J., Cheng, L., Xu, W., 2017. Applicability of TRMM satellite precipitation in driving hydrological model for identifying flood events: a case study in the Xiangjiang River basin, China. *Nat. Hazards* 87, 1489–1505. <https://doi.org/10.1007/s11069-017-2836-0>.
- Zeng, Q., Chen, H., Xu, C.Y., Jie, M.X., Chen, J., Guo, S.L., Liu, J., 2018. The effect of rain gauge density and distribution on runoff simulation using a lumped hydrological modelling approach. *J. Hydrol.* 563, 106–122. <https://doi.org/10.1016/j.jhydrol.2018.05.058>.
- Zhao, C., Ren, L., Yuan, F., Zhang, L., Jiang, S., Shi, J., Fernandez-Rodriguez, E., 2020. Statistical and hydrological evaluations of multiple satellite precipitation products in the yellow river source region of China. *Water* 12 (11), 3082. <https://doi.org/10.3390/w12113082>.

APÊNDICE C – MATERIAL SUPLEMENTAR: CAPÍTULO 2

Para preparar o Capítulo 2, foi realizado um estudo preliminar usando estações meteorológicas como fonte de dados de referência para comparar o desempenho dos produtos de precipitação. A forma como essa extração foi realizada e os resultados complementares dessa análise são apresentados a seguir. As observações de pluviômetros foram fornecidas pelo Instituto Nacional de Meteorologia (INMET; disponível on-line em www.inmet.gov.br). As séries temporais de precipitação mensal com mais de 20% de dados faltantes foram omitidas. 99 estações (Figura C1) foram selecionadas com base nesses critérios, com séries temporais de precipitação mensal que abrangem o período de 2000 a 2020. Cinco produtos de precipitação dos satélites CHIRPS, ERA5-Land, TERRACLIMATE, IMERG e TRMM para 2000-2020, com base no período de disponibilidade comum de cada conjunto de dados de precipitação, foram usados neste estudo (Tabela C1). Os dados foram coletados dos locais das estações meteorológicas usando a plataforma GEE (Gorelick et al., 2017).

Figura C1 – Mapa de classificação climática de Köppen para o NEB de acordo com Alvares et al. (2013), sub-regiões (polígonos amarelos) definidas pelo período chuvoso (Costa et al., 2020; Cunha et al., 2015) e localização dos biomas presentes no NEB e dos pluviômetros selecionados para o período 2000-2020. Os símbolos climáticos A, B e C significam Tropical, Semiárido e Subtropical Úmido, respectivamente




Figura C2 – Distribuições espaciais de pbias, r e RMSE da precipitação mensal do CHIRPS, TRMM, IMERG, TERRACLIMATE e ERA5-Land em comparação com os pluviômetros para o período de 2000 a 2020 no NEB




Tabela C1 – Resumo das estatísticas descritivas da precipitação mensal no NEB

Product	Validation statistics		
	pbias	RMSE	r
Chirps	-2.83	44.60	0.87
TRMM	2.11	43.38	0.90
IMERG	4.54	43.08	0.90
ERA5-Land	-14.21	57.25	0.82
TERRACLIMATE	-0.62	53.44	0.82

Figura C3 – Gráficos *Boxplots* de métricas de desempenho (pbias, RMSE e R) para cada mês de 2000 a 2020 para os produtos de precipitação (CHIRPS, TRMM, IMERG, TERRACLIMATE e ERA5-Land) no NEB





Figura C4 – Valores medianos das métricas de desempenho (pbias, RMSE e R) para cada mês do ano de 2000 a 2020 para os produtos de precipitação (CHIRPS, TRMM, IMERG, TERRACLIMATE e ERA5-Land) para três sub-regiões definidas pelo período chuvoso: (R1) janeiro a junho; (R2) março a agosto; e (R3) novembro a abril (Cunha et al., 2015, Costa et al., 2020). TERRAC: TERRACLIMATE, ERA5L: ERA5-Land




Figura C5 – Boxplot das métricas pbias, RMSE e r dos produtos CHIRPS, TRMM, IMERG, ERA5-Land e TERRACLIMATE para cada bioma do NEB (Amazônia, Caatinga, Cerrado e Mata Atlântica)



Para fornecer mais informações sobre o comportamento dos produtos de satélite, escolhemos uma estação para cada bioma, e foi realizada uma comparação entre a série temporal dos produtos de satélite e os dados observados in situ (Figura C6). Em geral, os produtos conseguiram captar adequadamente a variabilidade da precipitação no NEB e apresentam uma boa correspondência com os dados dos pluviômetros. No entanto, a tendência do TERRACLIMATE de superestimar a precipitação no bioma amazônico é evidente, especialmente durante a estação chuvosa.

Figura C6 - Série temporal de precipitação mensal - A) Bioma Caatinga (Caicó), B) Bioma Cerrado (Caxias), C) Mata Atlântica (Recife) e D) Bioma Amazônia (Turiacu) - derivada dos produtos de precipitação CHIRPS, TERRACLIMATE, ERA5-Land e TRMM e dos dados observados (INMET)



APÊNDICE D – MATERIAL SUPLEMENTAR: CAPÍTULO 3

A Figura D1 ilustra o desempenho dos produtos de precipitação e chuva baseados em terra (CHIRPS, ERA5, GLDAS, IMERG, MERRA-2, PERSIAN e TRMM) na simulação da vazão diária do rio durante os períodos de calibração (janeiro de 2000 a dezembro de 2005) e validação (janeiro de 2006 a agosto de 2010) usando o modelo hidrológico GR4J.

Figura D1 – Métricas de desempenho r , pbias e KGE para o produto baseado em pluviômetro e os sete produtos de precipitação diferentes na simulação da vazão diária dos rios nas bacias brasileiras nas fases de calibração e validação usando a abordagem I (ou seja, todos os modelos hidrológicos foram calibrados com o produto de precipitação medida no nível do solo)





Figura D2 – A diferença relativa entre os resultados r das avaliações diárias da vazão do rio e da precipitação para produtos de precipitação (CHIRPS, ERA5, GLDAS, IMERG, PERSIANN-CDR, MERRA-2 e TRMM) na calibração e validação para Abordagem I



Uma melhoria consistente no desempenho dos produtos de precipitação é observada à medida que a área da bacia hidrográfica aumenta (Fig. D3A), ao contrário da avaliação da descarga do rio (Fig. D3B). Para o conjunto de bacias hidrográficas com áreas menores que 1.000 km², muitas delas apresentaram bom desempenho ($r > 0,5$). A maioria das bacias hidrográficas com áreas variando entre 1.000 km² e 10.000 km² apresentou valores de $r > 0,6$; a explicação para esse comportamento provavelmente se deve ao fato de a precipitação média dos conjuntos de dados em grandes bacias hidrográficas ser mais representativa.

Figura D3 – Pontuações de desempenho em termos de r para os produtos de precipitação com diferentes áreas de bacia hidrográfica. Os histogramas representam o número de bacias hidrográficas $< 1.000 \text{ km}^2$ ($n = 204$), $1.000\text{-}10.000 \text{ km}^2$ ($n = 311$), $10.000\text{-}100.000 \text{ km}^2$ ($n = 161$) e $> 100.000 \text{ km}^2$ ($n = 38$): A) Desempenho das estimativas de precipitação em média na bacia hidrográfica, B) Eficiência do modelo hidrológico





Figura D4 – Valores dos parâmetros do modelo hidrológico derivados da fase de calibração usando cada produto de precipitação (GB-Ground-based rainfall, C-CHIRPS, E-ERA5, G-GLDAS, I-IMERG, MERRA-2, P-PERSIANN-CDR e T-TRMM) classificados por região hidrográfica de acordo com o índice de aridez (bacias mais secas à esquerda, bacias mais úmidas à direita)



Figura D5 – Boxplot para comparação entre as fases de calibração e validação da modelagem hidrológica usando o modelo GR4J e os cinco produtos de precipitação diferentes para as métricas de desempenho r , pbias e KGE



A Figura D6 mostra os resultados da simulação de vazão para quatro bacias hidrográficas em regiões brasileiras distintas. A primeira subparcela (D6a) corresponde à estação de monitoramento “Boa Sorte”, uma bacia hidrográfica com 210.502 km² no rio Xingu, localizada na região hidrográfica da Amazônia. A bacia hidrográfica recebe elevadas quantidades de precipitação com baixa variabilidade interanual e tem grande importância econômica e cultural para as comunidades que vivem ao longo das suas margens. Os resultados mostram uma boa concordância com todos os produtos de precipitação, bem como para o período de validação, com valores de KGE superiores a 0,81. A subparcela D6b ilustra os resultados da estação “Iraí”. Esta estação fica na bacia do rio Uruguai, na Mata Atlântica. Os resultados demonstram a alta confiabilidade dos produtos de precipitação e do modelo hidrológico para simular a vazão diária do rio nessas condições, com $KGE > 0,65$ para períodos de calibração e validação. A Figura D6c, por sua vez, está relacionada à estação de monitoramento “Tupiratins”, localizada na região hidrográfica Tocantins-Araguaia, no bioma Cerrado, que possui estações chuvosas e secas bem definidas. Nesta bacia hidrográfica, o CHIRPS apresenta melhor desempenho que os demais produtos na calibração, com $KGE = 0,93$, enquanto o IMERG, com $KGE = 0,60$, apresenta melhor desempenho na validação. A subparcela (D6d) corresponde ao medidor de vazão do riacho “Icó”, no bioma Caatinga, na região hidrográfica do Atlântico Leste. Esta estação monitora o rio Salgado, um dos principais afluentes do rio Jaguaribe. A estação Icó possui clima semiárido, com chuvas concentradas de fevereiro a maio. A evapotranspiração na região é bastante elevada, uma vez que a temperatura média anual é elevada e as chuvas são escassas. O período de calibração gera valores de KGE muito melhores que a validação, mas ainda é possível estimar a vazão fluvial com confiabilidade no período de validação com produtos de precipitação ($KGE > 0,40$), exceto para PERSIANN-CDR. Este produto apresentou calibração ($KGE=0,83$) e validação ($KGE=0,36$), indicando *overfitting* do modelo.

Figura D6 – Vazão diária simulada durante as fases de aquecimento, calibração e validação pelo GR4J com produtos de precipitação (CHIRPS, ERA5, GLDAS, IMERG, MERRA-2, PERSIANN-CDR e TRMM). A) Descarga diária do rio Xingu para o medidor de vazão "Boa Sorte" com uma área de bacia hidrográfica de 210502,9 Km². B) Descarga diária do rio Uruguai para o transdutor "Iraí" com uma área de bacia hidrográfica de 62087,86 Km². C) Descarga diária do rio Tocantins para o transdutor "Tupiratis", com uma área de bacia hidrográfica de 24.388,8 km². D) Descarga diária do rio Salgado para o medidor de vazão "Icó", com uma área de bacia hidrográfica de 12803,77 km²

