



**UNIVERSIDADE FEDERAL DA BAHIA**  
**ESCOLA POLITÉCNICA**  
**DEPARTAMENTO DE ENGENHARIA AMBIENTAL**

**DISSERTAÇÃO DE MESTRADO**

**ESTIMATIVAS DE PRECIPITAÇÃO POR SATÉLITE PARA DEFINIÇÃO DE  
EQUAÇÕES DE CHUVAS INTENSAS EM ÁREAS NÃO MONITORADAS DA  
MESORREGIÃO SUL BAIANO**

**RENAN BITENCOURT GARRIDO**

Salvador, BA  
2024



**UNIVERSIDADE FEDERAL DA BAHIA**  
**ESCOLA POLITÉCNICA**  
**DEPARTAMENTO DE ENGENHARIA AMBIENTAL**

**ESTIMATIVAS DE PRECIPITAÇÃO POR SATÉLITE PARA DEFINIÇÃO DE  
EQUAÇÕES DE CHUVAS INTENSAS EM ÁREAS NÃO MONITORADAS DA  
MESORREGIÃO SUL BAIANO**

**RENAN BITENCOURT GARRIDO**

Dissertação apresentada à Escola Politécnica da Universidade Federal da Bahia, como requisito parcial para a obtenção do título de Mestre em Meio Ambiente, Águas e Saneamento.

Orientadora: Profa. Dra. Andrea Sousa Fontes  
Co-orientadora: Profa. Dra. Yvonilde Dantas Pinto Medeiros

Salvador, BA  
2024

Ficha catalográfica elaborada pela Biblioteca Bernadete  
Sinay Neves, Escola Politécnica - UFBA.

---

G241 Garrido, Renan Bitencourt.

Estimativas de precipitação por satélite para definição de equações  
de chuvas intensas em áreas não monitoradas da mesorregião sul baiano /  
Renan Bitencourt Garrido. – Salvador, 2024.

100 f.: il. color.

Orientadora: Profa. Dra. Andrea Sousa Fontes.

Coorientadora: Profa. Dra. Yvonilde Dantas Pinto Medeiros.

Dissertação (mestrado) – Programa de Pós-graduação em Meio  
Ambiente, Águas e Saneamento - Universidade Federal da Bahia - Escola  
Politécnica, 2024.

1. Curvas IDF. 2. CHIRPS. 3. Correção de viés. I. Fontes, Andrea  
Sousa. II. Medeiros, Yvonilde Dantas Pinto. III. Universidade Federal da  
Bahia. IV. Título.

---

CDD: 551.577



Programa de pós-graduação em Meio Ambiente, Águas e Saneamento.

UNIVERSIDADE FEDERAL DA BAHIA  
ESCOLA POLITÉCNICA



Renan Bitencourt Garrido

**ESTIMATIVAS DE PRECIPITAÇÃO POR SATÉLITE PARA DEFINIÇÃO DE  
EQUAÇÕES DE CHUVAS INTENSAS EM ÁREAS NÃO MONITORADAS DA  
MESORREGIÃO SUL BAIANO**

Banca Examinadora:



Documento assinado digitalmente

**ANDREA SOUSA FONTES**  
Data: 18/12/2024 12:04:17-0300  
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Andrea Sousa Fontes  
Universidade Federal da Bahia



Documento assinado digitalmente

**YVONILDE DANTAS PINTO MEDEIROS**  
Data: 19/12/2024 10:05:01-0300  
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Yvonilde Dantas Pinto Medeiros  
Universidade Federal da Bahia



Documento assinado digitalmente

**LAFAYETTE DANTAS DA LUZ**  
Data: 19/12/2024 11:30:17-0300  
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Lafayette Dantas da Luz  
Universidade Federal da Bahia



Documento assinado digitalmente

**IANA ALEXANDRA ALVES RUFINO**  
Data: 19/12/2024 06:49:39-0300  
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Iana Alexandra Alves Rufino  
Universidade Federal de Campina Grande

Salvador  
18 de dezembro de 2024

## AUTORIZAÇÃO

**Autorizo a reprodução e/ou divulgação total ou parcial da presente obra, por qualquer meio convencional ou eletrônico, desde que citada a fonte**

Nome do autor: Renan Bitencourt Garrido

Instituição: Universidade Federal da Bahia

Endereço: Rua Aristides Novis, 02, 4º andar, Federação, Salvador, Bahia

Email: eng.renangarrido@gmail.com

Assinatura do autor:

---

## RESUMO

Produtos de precipitação por satélite podem ser uma alternativa importante para a determinação de equações IDF em regiões não monitoradas, em busca de sistemas hidráulicos mais resilientes aos impactos das inundações. Este trabalho avaliou as estimativas de precipitação do produto CHIRPS para a determinação de equações IDF na Mesorregião Sul Baiano. As métricas estatísticas utilizadas foram o Bias Percentual (PBIAS), a Raíz do Erro Quadrático Médio (RMSE), o Erro Absoluto Médio (MAE), e o coeficiente de eficiência de Nash-Sutcliffe (NSE). Os resultados indicam que o CHIRPS não apresenta desempenho satisfatório em seu estado original (PBIAS 21,54%; RMSE 43,56 mm/h; MAE 42,74 mm/h; NSE -2,78), mas pode fornecer equações IDF razoáveis se o viés dos dados for corrigido (PBIAS -4,75%; RMSE 10,09 mm/h; MAE 9,03 mm/h; NSE 0,78). A partir de um modelo de regressão linear, foi proposto um outro método de correção de viés que pode ser aplicado, com algumas limitações, em áreas não monitoradas da região estudada, utilizando apenas coordenadas geográficas (PBIAS -3,77%; RMSE 15,46 mm/h; MAE 14,41 mm/h; NSE 0,45). A utilização de dados do CHIRPS corrigidos pelo método proposto apresentou desempenho superior quando comparada a curvas IDF fornecidas pelo software Plúvio 2.1 (PBIAS 13,56%; RMSE 28,25 mm/h; MAE 26,84 mm/h; NSE -0,55), amplamente utilizado por engenheiros/projetistas. Por fim, os modelos não estacionários para análise de frequência se mostraram mais apropriados quando a condição de tendência nas séries é identificada. Além disso, verificou-se pelos critérios de AIC, BIC e teste da razão de verossimilhança que os modelos com menor número de parâmetros foram preferidos em relação aos modelos mais complexos, prevalecendo a distribuição de Gumbel em relação à distribuição GEV.

**Palavras-chave:** curvas IDF; CHIRPS; correção de viés.

## **ABSTRACT**

Satellite-based precipitation products can be an important alternative for developing IDF equations in ungauged regions, in search for more flood-resilient hydraulic systems. This study evaluated precipitation estimates from the product CHIRPS for developing IDF equations in the Southern Bahia Mesoregion. The statistical metrics used were Percent Bias (PBIAS), Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and the Nash-Sutcliffe Efficiency coefficient (NSE). The results indicate that CHIRPS does not perform satisfactorily in its original state (PBIAS 21.54%; RMSE 43.56 mm/h; MAE 42.74 mm/h; NSE -2.78), but it can provide reasonable IDF equations if the data bias is corrected (PBIAS -4.75%; RMSE 10.09 mm/h; MAE 9.03 mm/h; NSE 0.78). Based on a linear regression model, a bias correction method was proposed, which can be applied, with some limitations, in ungauged areas of the studied region, using only geographic coordinates (PBIAS -3.77%; RMSE 15.46 mm/h; MAE 14.41 mm/h; NSE 0.45). Using CHIRPS data corrected by the proposed method showed higher performance when compared to IDF curves provided by the Plúvio 2.1 software (PBIAS 13.56%; RMSE 28.25 mm/h; MAE 26.84 mm/h; NSE -0.55), which is commonly used by engineers/designers. Finally, non-stationary models for frequency analysis proved to be more appropriate when a trend condition in the series is identified. Furthermore, based on the AIC, BIC criteria, and the likelihood ratio test, models with fewer parameters were preferred over more complex models, with the Gumbel distribution outperforming the GEV distribution.

**Keywords:** IDF curves; CHIRPS; bias correction.

## SUMÁRIO

<b>LISTA DE FIGURAS</b> .....	<b>v</b>
<b>LISTA DE QUADROS</b> .....	<b>vi</b>
<b>LISTA DE TABELAS</b> .....	<b>vii</b>
<b>LISTA DE ABREVIATURAS E SIGLAS</b> .....	<b>ix</b>
<b>1. INTRODUÇÃO</b> .....	<b>1</b>
1.1. Pergunta orientadora.....	4
1.2. Hipóteses .....	4
<b>2. OBJETIVOS</b> .....	<b>5</b>
2.1. Objetivo geral .....	5
2.2. Objetivos específicos.....	5
<b>3. REVISÃO BIBLIOGRÁFICA</b> .....	<b>5</b>
3.1. Chuvas intensas e inundações urbanas.....	5
3.2. Aquisição de dados de precipitação .....	7
3.2.1. Pluviômetros e pluviógrafos .....	7
3.2.2. Estimativas de precipitação por satélite .....	10
3.3. Equações IDF .....	13
3.3.1. Método das relações de chuvas de diferentes durações .....	16
3.4. Relações IDF sob a perspectiva de não estacionariedade.....	19
3.4.1. Identificação de tendência em séries temporais .....	21
3.4.2. Análise de frequência sob a hipótese de não estacionariedade .....	24
<b>4. MATERIAIS E MÉTODOS</b> .....	<b>26</b>
4.1. Área de estudo .....	26
4.2. Procedimentos metodológicos .....	28
4.3. Dados de precipitação observados <i>in situ</i> .....	29
4.4. Dados de precipitação estimados por satélite .....	30
4.5. Avaliação do CHIRPS para determinação de curvas IDF na área de estudo	
31	
4.5.1. Determinação das curvas IDF .....	31
4.5.2. Validação das curvas IDF geradas pelos dados de satélite .....	34
4.6. Correção de viés dos dados de satélite.....	35
4.6.1. Proposta de correção de viés para áreas não monitoradas .....	36
4.7. Análise de frequência sob a ótica da não estacionariedade.....	37
4.7.1. Identificação de tendência nas séries temporais.....	37
4.7.2. Análise de frequência sob hipótese de não estacionariedade .....	40
<b>5. RESULTADOS E DISCUSSÃO</b> .....	<b>43</b>
5.1. Validação dos dados de sensoriamento remoto.....	43

5.1.1.	Desempenho das curvas IDF estimadas pelo CHIRPS .....	43
5.2.	Proposta de correção de viés para utilização para áreas não monitoradas	49
5.2.1.	Desempenho das curvas IDF após a correção de viés.....	55
5.3.	Análise de frequência sob hipótese de não estacionariedade.....	61
5.3.1.	Análises estatísticas.....	61
5.3.2.	Escolha do modelo.....	64
<b>6.</b>	<b>CONCLUSÕES .....</b>	<b>68</b>
	<b>REFERÊNCIAS.....</b>	<b>71</b>
	<b>APÊNDICE A .....</b>	<b>86</b>

## LISTA DE FIGURAS

Figura 1 - Curva de inundação para bacias urbanas da Região Serrana do Rio de Janeiro.....	6
Figura 2 - Características de um pluviômetro de leitura manual (a) e um de leitura automática com base no mecanismo de cubas basculantes (b) .....	8
Figura 3 - Localização da Mesorregião Sul Baiano .....	26
Figura 4 - Mapas de classificação climática (a), precipitação total anual média (b) e localização das estações utilizadas (c).....	27
Figura 5 - Fluxograma metodológico da pesquisa.....	29
Figura 6 – Relação entre o fator de correção de viés ( $f_{cv}$ ) e a longitude (a), latitude (b), PRCPTOT (c) e Elevação (d) .....	50
Figura 7 – Interpolação do $f_{cv}$ ao longo da Mesorregião Sul Baiano.....	51
Figura 8 – Interpolação do Erro Padrão (E) do $f_{cv(reg)}$ em relação ao $f_{cv}$ original .....	54
Figura 9 - MAE para os dados do CHIRPS: a) Original, b) Corrigidos (1) e c) Corrigidos (2) .....	58
Figura 10 – Interpolação do MAE para a) IDFs fornecidas pelo Plúvio e b) Estimadas pelo CHIRPS após correção de viés (2) .....	60
Figura 11 - Séries de PMDA com as respectivas linhas de tendência .....	61

## LISTA DE QUADROS

Quadro 1 - Características de alguns produtos de sensoriamento remoto para estimativas de precipitação .....	10
Quadro 2 - Sistematização dos procedimentos realizados.....	28
Quadro 3 – Resumo dos dados utilizados na pesquisa.....	31
Quadro 4 - Funções densidade de probabilidade (FDPs) disponíveis para modelagem probabilística no GAM-IDF .....	32
Quadro 5 - Coeficientes de desagregação para diferentes durações utilizados pelo GAM-IDF .....	33
Quadro 6 - Métricas estatísticas utilizadas na avaliação .....	34
Quadro 7 - Estações pluviométricas da ANA utilizadas.....	86

## LISTA DE TABELAS

Tabela 1 - Limites mínimos de chuvas intensas de Pfafstetter.....	6
Tabela 2 - Coeficientes de desagregação para diferentes durações de chuva .....	17
Tabela 3 - Valores médios de precipitação em relação à chuva de 24h .....	18
Tabela 4 - Relações médias de chuva encontradas por Matos (2006) e outros estudos .....	18
Tabela 5 - Classificação dos indicadores estatísticos de desempenho PBIAS e NSE .....	35
Tabela 6 - Resultado do processamento das curvas IDF a partir dos dados observados no GAM-IDF .....	44
Tabela 7 - Resultado do processamento das curvas IDF a partir de dados do CHIRPS no GAM-IDF .....	45
Tabela 8 – Intensidades (mm/h) calculadas para uma chuva de 10 min de duração	46
Tabela 9 - Indicadores estatísticos de desempenho do CHIRPS .....	47
Tabela 10 - Classificação dos resultados de PBIAS e NSE .....	47
Tabela 11 – Fator de correção de viés calculado para as estações.....	49
Tabela 12 - Modelos de regressão linear testados para correção de viés .....	52
Tabela 13 - Estatística dos coeficientes estimados para cada modelo de regressão	52
Tabela 14 - Resultado dos fatores de correção de viés calculados a partir dos modelos de regressão e seus respectivos erros em relação ao $f_{cv}$ original .....	53
Tabela 15 - Indicadores estatísticos de desempenho após a aplicação do $f_{cv}$ .....	55
Tabela 16 - Resultados obtidos pelos indicadores estatísticos de desempenho após a aplicação do $f_{cv (reg)}$ .....	56
Tabela 17 – Classificação dos resultados obtidos pelos indicadores estatísticos de desempenho PBIAS e NSE .....	57
Tabela 18 - Comparação entre o desempenho obtido pelas IDFs fornecidas pelo Plúvio e as IDFs estimadas pelo CHIRPS após aplicação do $f_{cv (reg)}$ (Corrigido 2) ...	59
Tabela 19 - Classificação dos resultados obtidos pelos indicadores estatísticos de desempenho PBIAS e NSE da Tabela 18 .....	59
Tabela 20 - Resumo das análises estatísticas .....	62
Tabela 21 - Interpretação dos resultados da Tabela 20 .....	63
Tabela 22 - Estimativas dos parâmetros das distribuições e critérios de seleção para Camacan .....	64

Tabela 23 - Estimativas dos parâmetros das distribuições e critérios de seleção para Aratuípe .....	65
Tabela 24 - Estimativas dos parâmetros das distribuições e critérios de seleção para Helvécia .....	65
Tabela 25 - Estimativas dos parâmetros das distribuições e critérios de seleção para São Pedro do Pampã .....	66
Tabela 26 - Chuva máxima diária (mm) calculada pelos modelos para os TR de 2 e 20 anos na estação de Camacan .....	67
Tabela 27 - Chuva máxima diária (mm) calculada pelos modelos para os TR de 2 e 20 anos na estação de São Pedro do Pampã .....	68
Tabela 28 - Chuva máxima diária (mm) calculada pelos modelos estacionários para os TR de 2 e 20 anos nas estações de Aratuípe e Helvecia .....	68

## LISTA DE ABREVIATURAS E SIGLAS

AIC	Critério de Informação de Akaike
ANA	Agência Nacional de Águas e Saneamento Básico
BIC	Critério de Informação Bayesiano
CETESB	Companhia Ambiental do Estado de São Paulo
CHIRPS	Climate Hazards Group InfraRed Precipitation with Stations
DLL	Design Life Level
DNOS	Departamento Nacional de Obras de Saneamento
$f_{cv}$	Fator de Correção de Viés
FDP	Função Densidade de Probabilidade
GAM-IDF	Genetic Algorithm Methodology for IDF
GEV	Generalizada de Valores Extremos
Hidroweb	Sistema de Informações Hidrológicas da ANA
LRT	Teste de Razão de Verossimilhança
IBGE	Instituto Brasileiro de Geografia e Estatística
IDF	Intensidade-Duração-Frequência
INMET	Instituto Nacional de Meteorologia
IPCC	Painel Intergovernamental sobre Mudanças Climáticas
MAE	Erro Absoluto Médio
MSWEP	Multi-Source Weighted-Ensemble Precipitation
NSE	Coeficiente de Eficiência de Nash-Sutcliffe
PMDA	Precipitação Máxima Diária Anual
PRCPTOT	Precipitação Total Anual Média
RMSE	Raíz do Erro Quadrático Médio
TR	Tempo de Retorno
UCSB	University of California, Santa Barbara
USGS	United States Geological Survey

## 1. INTRODUÇÃO

As inundações são os desastres mais frequentes no mundo inteiro e são capazes de causar impactos severos, como perdas de vidas humanas, danos estruturais consideráveis e prejuízos econômicos significativos (Dinis et al., 2021; Kasi et al. 2020; Parvin et al., 2016; Ramos Filho et al., 2022). Ao longo das últimas décadas, quase 20 mil pessoas perderam suas vidas em todo o mundo, e aproximadamente 58 milhões foram impactadas por enchentes severas (Red Cross, 2010; World Bank, 2018; Kumar et al., 2021). Chuvas intensas em ambientes urbanos podem ser fortes indicativos deflagradores da ocorrência de inundações/enchentes e deslizamentos de terra, especialmente em áreas de risco como regiões ribeirinhas e encostas (Valverde, 2018; Yu et al., 2022). A investigação de tais eventos extremos vem ganhando destaque na comunidade científica internacional por conta dos danos socioeconômicos e ambientais que o excesso de chuvas causa em diversas regiões do planeta (Ferreira et al., 2017).

A fim de minimizar os efeitos das chuvas intensas, são construídos nos ambientes urbanos sistemas de drenagem e controle de enchentes, que são medidas fundamentais para conduzir o escoamento e evitar ou mitigar os impactos de inundações (Binesh et al., 2019). Para isso, uma estimativa precisa da vazão de projeto utilizada para o dimensionamento de estruturas hidrológicas/hidráulicas é necessária (Venkatesh et al., 2022). Essa estimativa pode ser obtida através de uma série de dados observados de vazão ou a partir de um modelo chuva-vazão baseado em chuva de projeto (Dorneles et al., 2019; Lima Neto et al., 2021; Suzuki et al., 2022). Geralmente, o dimensionamento dessas estruturas demanda o estudo das três variáveis que caracterizam o comportamento da precipitação de cada região: a intensidade, a duração e a frequência (IDF) (Dorneles et al., 2019). O conhecimento de tais variáveis permite a determinação de uma equação IDF, que também pode ser expressa no formato de curvas IDF, sendo a principal ferramenta para representar as chuvas intensas de um determinado local (Noor et al., 2018, 2021; Sabino et al., 2020).

Em muitos países, inclusive o Brasil, a determinação de equações IDF ainda é desafiadora, devido à insuficiência de registros pluviográficos, especialmente para durações sub-diárias, principalmente pela baixa densidade da rede de monitoramento, quantidade elevada de falhas e curto período de observações disponível (Back, 2009;

Back et al., 2012; Abreu et al., 2022; Aragão et al., 2024; Barbosa et al., 2022; F. Costa et al., 2024; Freitas et al., 2020; Nunes et al., 2021; Soares et al., 2016). Segundo Ombadi et al. (2018), a disponibilidade de registros pluviométricos longos com distribuição espacial adequada é limitada e incapaz de refletir a variação temporal e a heterogeneidade espacial da precipitação. Além disso, a disponibilidade de dados de precipitação em escala sub-diária é baixa, sendo mais comum o monitoramento em escala diária, o que requer utilização de métodos de desagregação de chuva, que podem não ser apropriados para a região (Abreu et al., 2022).

A fim de ampliar a disponibilidade de dados, produtos de estimativa de precipitação por meio de sensoriamento remoto (Nguyen et al., 2020; Beck et al., 2019; Huffman et al., 2019; Sabater, 2019; Funk et al., 2015; Chen et al., 2008) se tornaram uma importante alternativa (Llauca et al., 2021), principalmente por conta da ampla cobertura espacial e resolução espaço-temporal apurada (Min et al., 2020). No entanto, esses produtos devem ser utilizados com cautela, sendo necessário verificar a precisão das suas estimativas. Diversos estudos indicam que os produtos de precipitação por satélite apresentam erros aleatórios e também sistemáticos, especialmente na detecção de valores extremos de precipitação (Ombadi et al., 2018; Prakash et al., 2016; Sadeghi et al., 2021). Apesar da ampla cobertura espacial, os dados de satélite também são majoritariamente disponibilizados em resolução temporal diária. Alguns produtos disponibilizam dados em escalas temporais menores, mas apresentam alta imprecisão nas estimativas (Freitas et al., 2020; Ramos Filho et al., 2022; Trang et al., 2020). Entretanto, diversos estudos desenvolveram métodos de correção de viés dos dados de satélite que melhoram significativamente a precisão das estimativas (Mianabadi, 2023; Ombadi et al., 2018; Venkatesh et al., 2022). Sendo assim, é importante ressaltar que a medição direta em campo ainda é a fonte de dados de precipitação mais precisa, no entanto, o monitoramento da precipitação por satélite é uma alternativa promissora, que tem potencial para se tornar uma fonte de dados cada vez mais confiável.

Ainda que haja disponibilidade de registros de precipitação com resolução espaço-temporal adequada, outra limitação tem chamado atenção da comunidade científica. Tradicionalmente, as equações IDF são definidas com base em longos registros históricos de precipitação, que retratam o passado da região, mas podem não refletir os possíveis efeitos de alterações climáticas. Dessa forma, as estruturas hidráulicas

dimensionadas com base nessas equações podem perder a sua capacidade de resposta ao longo dos anos (Kang et al., 2016), o que indica a necessidade de atualização dessas equações com uma certa frequência. Além disso, o estudo das relações IDF requer a aplicação de métodos probabilísticos, assim como outras análises da hidrologia e recursos hídricos. Isso ocorre porque a maioria, se não todos, os processos hidrológicos, como eventos extremos, têm algum grau de aleatoriedade. A maioria dos estudos sobre métodos probabilísticos usados no planejamento de estruturas hidráulicas parte do pressuposto de que os eventos hidrológicos extremos são estacionários. No entanto, investigações têm revelado que em alguns lugares os registros hidrológicos apresentam algum tipo de não estacionariedade (Milly et al., 2008; Villarini et al., 2009a; Salas e Obeysekera, 2014; Nunes et al., 2021).

A interferência humana é uma das principais razões pelas quais o ciclo hidrológico das bacias fluviais passa por mudanças. Por exemplo, os registros de precipitação e vazão podem estar se alterando devido às transformações no uso da terra nas bacias, como o aumento da urbanização (Villarini et al., 2009b; Hejazi e Markus, 2009; Vogel et al., 2011), o desenvolvimento agrícola (Schilling e Libra, 2007; Pielke et al., 2007) e a degradação em larga escala das florestas (Gash e Nobre, 1997). Essas interferências na paisagem modificam características da resposta hidrológica, como a magnitude e o tempo das inundações extremas. Além disso, tornou-se aparente que algumas das alterações observadas pelos pesquisadores nos registros hidrológicos podem ser atribuídas ao impacto da variabilidade climática natural, especialmente decorrente de componentes de baixa frequência da variabilidade climática, como o El Niño Oscilação Sul (ENOS), e oscilações de longo prazo, como a Oscilação Decadal do Pacífico (PDO) e a Oscilação Multidecadal do Atlântico (AMO) (Enfield et al., 2001; McCabe e Wolock, 2002; Franks e Kuczera, 2002; Kiem et al., 2003; Park et al., 2010, 2011).

Outro motivo para o aumento na atenção dada à não estacionariedade é a preocupação crescente com as mudanças climáticas devido ao aumento dos gases de efeito estufa na atmosfera. Segundo o Painel Intergovernamental sobre Mudanças do Clima (IPCC), as emissões de gases de efeito estufa provocadas pelas atividades humanas têm causado aumento na intensidade e frequência de eventos climáticos extremos desde 1850, principalmente extremos de temperatura e precipitação. No seu sexto relatório, o IPCC indica que o sudeste da América do Sul pode apresentar

aumento na intensidade de chuva (IPCC, 2021). Ademais, diversos estudos têm registrado por meio da observação e de projeções climáticas o aumento da frequência de eventos extremos em algumas regiões do mundo (Sun et al., 2021; Tabari, 2021; Wasko et al., 2021), inclusive do Brasil (Marengo et al., 2013; Natividade et al., 2017; Nunes et al., 2021; Ribeiro et al., 2019; Xavier et al., 2020).

A ocorrência de eventos de chuva no Brasil, com alta magnitude e significativos impactos vem sendo observada, como, por exemplo, as chuvas intensas que ocorreram nos anos de 2021, 2022, 2023 e 2024, com destaque, neste trabalho, para os eventos do sul da Bahia. Esses eventos resultaram em diversos pontos de inundações, vítimas fatais, famílias desabrigadas e decretos de situação de emergência em diversos municípios no sul do estado. Em 2021, 24 pessoas morreram e 629 mil foram afetadas em toda a Bahia (G1 Bahia e TV Santa Cruz, 2022).

Nesse contexto, o presente trabalho visa contribuir com a discussão e o conhecimento das relações intensidade, duração e frequência de chuvas contemplando a hipótese de não estacionariedade das séries históricas e variabilidade espacial dos padrões de precipitação, em busca de sistemas mais resilientes frente às novas e futuras condições climáticas. O trabalho está sendo desenvolvido no âmbito do projeto aprovado pelo PEPEEC - Programa Emergencial de Prevenção e Enfrentamento de Desastres Relacionados a Emergências Climáticas, eventos extremos, acidentes ambientais, financiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

### **1.1. Pergunta orientadora**

Como as relações entre intensidade, duração e frequência de chuvas podem ser melhor representadas de modo a subsidiar o dimensionamento de estruturas hidráulicas em áreas não monitoradas da Mesorregião Sul Baiano visando adaptação aos eventos climáticos extremos?

### **1.2. Hipóteses**

- A incorporação de produtos de satélite para quantificação da precipitação permite melhor representar as relações IDF em áreas não monitoradas da Mesorregião Sul Baiano;

- As séries temporais de precipitação podem não ser estacionárias, e a utilização de modelos de análise de frequência adaptados à esta condição pode proporcionar estimativas de chuva de projeto mais assertivas, visando adaptação às alterações climáticas.

## **2. OBJETIVOS**

### **2.1. Objetivo geral**

Analisar a aplicação de estimativas de precipitação por satélite para definição de relações Intensidade-Duração-Frequência (IDF) a fim de subsidiar o dimensionamento de estruturas hidráulicas em áreas não monitoradas da Mesorregião Sul Baiano, considerando a variabilidade climática das séries históricas.

### **2.2. Objetivos específicos**

- Avaliar o desempenho de estimativas de precipitação por satélite na determinação de relações IDF na região de estudo;
- Avaliar a aplicabilidade das estimativas de precipitação por satélite em áreas não monitoradas da região de estudo;
- Analisar as séries temporais de precipitação na região de estudo sob a ótica de não estacionariedade.

## **3. REVISÃO BIBLIOGRÁFICA**

### **3.1. Chuvas intensas e inundações urbanas**

Desastres associados a inundações são os mais frequentes no mundo e são capazes de causar impactos severos, como perdas de vidas humanas, danos estruturais consideráveis e prejuízos econômicos significativos (Dinis et al., 2021; Kasi et al. 2020; Parvin et al., 2016; Ramos Filho et al., 2022). Segundo relatório das Nações Unidas, elas foram responsáveis por quase 50% dos desastres associados a fatores climáticos e afetaram 2,3 bilhões de pessoas no mundo entre 1995 e 2015, sendo uma parcela significativa residentes de áreas urbanas. O relatório destaca também que os países com maior número de pessoas afetadas pelas inundações são China e Índia, representando 75% das pessoas afetadas em todo o mundo, e o Brasil é o único país das Américas que aparece na lista dos 10 países mais afetados, com 51 milhões de pessoas atingidas no período analisado (UN, 2015).

Os eventos de inundação estão geralmente associados à ocorrência de chuvas intensas, também denominadas chuvas extremas ou máximas, as quais apresentam grande lâmina precipitada durante um pequeno intervalo de tempo, sendo frequentemente associadas a prejuízos materiais e humanos (Silva et al., 2003).

Alguns autores como Pfafstetter (1957), estabeleceram limites mínimos para se caracterizar uma chuva intensa conforme Tabela 1, porém, segundo Pinto (1995), a definição de um valor fixo para isso na prática é desafiador, visto que depende do local onde a precipitação ocorre, variando o impacto e os danos causados entre ambientes urbanos e rurais.

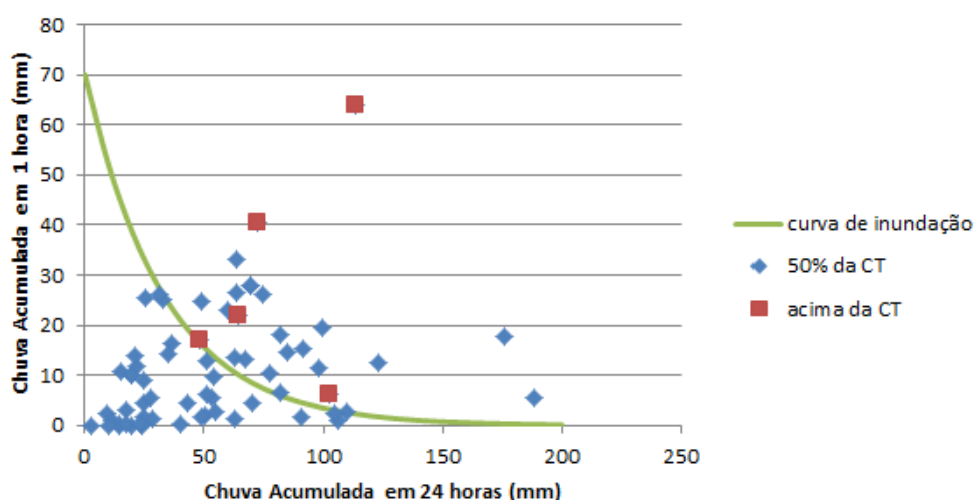
**Tabela 1 - Limites mínimos de chuvas intensas de Pfafstetter**

Duração (min)	Precipitação (mm)	Duração (min)	Precipitação (mm)
5	8	240	35
15	15	480	40
30	20	840	47
60	25	1440	55
120	30	2880	70

Fonte: Pfafstetter (1957)

Diversos trabalhos buscaram relacionar as chuvas intensas e o acumulado de chuva com a ocorrência de inundações (Choo et al., 2019; Norbiato et al., 2008). Bacelar et al. (2013), propuseram uma curva de inundação, para bacias urbanas da Região Serrana do Rio de Janeiro, capaz de indicar o quanto deve chover em uma hora para haver aumento na probabilidade de eventos críticos, com base no acumulado de chuva em 24h (Figura 1).

**Figura 1 - Curva de inundação para bacias urbanas da Região Serrana do Rio de Janeiro**



Fonte: Bacelar et al. (2013) – (CT = cota de transbordamento do rio)

O estudo de chuvas intensas é um dos produtos de maior aplicação na hidrologia, especialmente na determinação de chuvas de projeto e na análise de estruturas hidráulicas como bueiros, pontes, canais e vertedores (Mello et al., 2008; Collischonn e Dornelles, 2015). O dimensionamento dessas estruturas envolve o conhecimento da vazão associada a um determinado tempo de retorno, entretanto, uma série histórica desta variável nem sempre está disponível, sendo mais comum o registro de dados de precipitação. Assim, a análise de chuvas intensas pode ser utilizada para determinar as vazões máximas em uma determinada bacia ou a vazão de projeto. Nesse caso, a vazão de projeto é calculada a partir das curvas ou equações de intensidade, duração e frequência (IDF), que são uma das ferramentas mais aplicadas na engenharia de recursos hídricos (Goulart et al., 1992; Koutsoyiannis et al., 1998; Tucci, 2009).

A análise de chuvas intensas é realizada com base em conceitos de probabilidade aplicados às séries históricas de precipitações máximas associadas a diferentes durações em um determinado local. O método mais amplamente utilizado para estimativa de uma chuva intensa é através das equações de chuvas intensas, determinadas a partir de séries históricas medidas em pluviógrafos (Back et al., 2011; Tucci, 2009).

## **3.2. Aquisição de dados de precipitação**

### **3.2.1. Pluviômetros e pluviógrafos**


No Brasil, de forma geral, a chuva é medida por meio de instrumentos de leitura direta, chamados de pluviômetros ou por aparelhos adaptados para fazer registros de forma contínua, denominados de pluviógrafos. O primeiro instrumento permite apenas a leitura do volume precipitado entre duas medições consecutivas, enquanto o segundo é capaz de registrar o volume precipitado em função do tempo (Ayoade, 2003).

O pluviômetro mais comum no Brasil tem um formato cilíndrico com uma área superior de captação da chuva de 400 cm<sup>2</sup>, de modo que um volume de 40 ml de água acumulado no recipiente equivale a 1 mm de chuva. O instrumento deve ser instalado a uma altura padrão de 1,50 m do solo (Figura 2a) e a uma certa distância de casas, árvores e outros obstáculos que podem interferir na quantidade de chuva captada. (Collischonn e Dornelles, 2015).

Os pluviógrafos, por sua vez, são instrumentos automáticos que medem a precipitação, sendo possível determinar a intensidade através da razão entre a precipitação da chuva pelo intervalo de tempo. Originalmente, estes equipamentos contavam com um papel para registro da chuva de forma analógica, mas foram substituídos por aparelhos digitais com *data loggers* para registrar automaticamente as informações e com dispositivos telemétricos que enviam, também de forma automática, os dados obtidos para as centrais de dados. Assim como o pluviômetro, ele possui um receptor cônico, porém sua área de captação é de apenas 200 cm<sup>2</sup> (ANA, 2013; Garcez e Alvarez, 1988).

O pluviógrafo mais utilizado atualmente é o de cubas basculantes (Figura 2b), em que a água coletada é direcionada para um conjunto de duas cubas articuladas por um eixo central. Inicialmente a água é dirigida para uma das cubas e quando esta recebe uma quantidade de água equivalente a 20g, aproximadamente, o conjunto gira em torno do eixo, esvaziando a primeira cuba e a segunda começa a receber água. Cada movimento das cubas basculantes corresponde a uma lâmina precipitada (por exemplo 0,2 mm), e o aparelho registra o número de movimentos e o tempo entre eles (Collischonn e Dornelles, 2015).

**Figura 2 - Características de um pluviômetro de leitura manual (a) e um de leitura automática com base no mecanismo de cubas basculantes (b)**



Fonte: Adaptado de Collischonn e Dornelles (2015).

A rede pluviométrica do Brasil é muito mais abrangente que a rede pluviográfica, que é de baixa densidade e mal distribuída, principalmente em regiões tropicais, como o Nordeste brasileiro, devido aos custos mais elevados de aquisição e manutenção dos pluviógrafos em relação aos pluviômetros (Freitas et al., 2020; Lewis et al., 2019; Oliveira et al., 2008).

Segundo Back et al. (2012), a leitura dos dados registrados nas estações meteorológicas brasileiras é feita normalmente às 9 horas da manhã e nas estações da Agência Nacional de Águas e Saneamento Básico (ANA), às 7 horas da manhã, com um intervalo fixo de 24h entre as leituras, configurando a chamada chuva de 1 dia (Villela e Mattos, 1975). Geralmente, essa precipitação acumulada observada antes do meio-dia corresponde à chuva do dia anterior. No caso do pluviógrafo, a chuva é registrada de forma contínua ao longo de um período de 24 horas, a partir de qualquer instante, caracterizando a chamada chuva de 24 horas (Back, 2009; Tucci, 2009).

Back (2009) ressalta que, as leituras nos pluviômetros podem subestimar a chuva máxima de 24 horas visto que são efetuadas sempre no mesmo horário e, portanto, a chuva registrada pode ficar dividida em dois dias. Essa distinção pode ser prejudicial para o projeto de estruturas hidráulicas, que devem ser dimensionados para resistir as chuvas máximas esperadas para um determinado intervalo de tempo, geralmente em função do custo e risco da obra.

Devido a isso, diversos autores propõem relações entre a chuva máxima de 24 horas e a chuva máxima de 1 dia. Observa-se que essa relação é praticamente invariável para qualquer tempo de retorno (Back, 2009), e o valor de 1,14 proposto pela CETESB (1986) é o mais adotado no Brasil, porém encontra-se na literatura diversos trabalhos propondo relações que variam de 1,095 a 1,24, considerando diferentes localidades (Back, 2006; Back et al., 2012; Back e Pola, 2016). Sendo assim, nota-se que esta relação pode variar de acordo com a região, o que indica que a determinação de coeficientes locais pode ser importante para representar de forma mais precisa o comportamento da chuva de cada lugar.

Presotto (2020) investigou a relação entre as chuvas de 24h e as chuvas de 1 dia no Estado do Rio Grande do Sul comparando séries de dados pluviométricos e pluviográficos. Neste estudo, a relação média entre precipitações de 24h e 1 dia foi de 1,09, tendo uma diferença de 4,6% quando comparada com a relação recomendada pela CETESB e largamente utilizada no Brasil que é de 1,14. Ao avaliar separadamente estas relações de 24h/1dia para cada estação pluviográfica utilizada, o autor observou que elas variaram de 1,01 até 1,18, ficando dentro da faixa de valores já existentes nos estudos citados no parágrafo anterior, que variam de 1,095 a 1,24.

### 3.2.2. Estimativas de precipitação por satélite

Devido às dificuldades citadas anteriormente com relação a rede pluviográfica brasileira, a disponibilidade de dados de precipitação medida em campo é limitada. Desta forma, produtos de estimativa de precipitação por meio de sensoriamento remoto (Nguyen et al., 2020; Beck et al., 2019; Huffman et al., 2019; Sabater, 2019; Funk et al., 2015; Chen et al., 2008) se tornaram uma importante alternativa (Llauca et al., 2021), principalmente por conta da ampla cobertura espacial e resolução espaço-temporal apurada (Min et al., 2020). O Quadro 1 apresenta alguns dos principais produtos de satélite utilizados para obtenção de dados de precipitação.

**Quadro 1 - Características de alguns produtos de sensoriamento remoto para estimativas de precipitação**

Produto	Nome	Resolução Temporal	Resolução Espacial	Disponibilidade de Dados
<b>MSWEP V2</b>	Multi-Source Weighted-Ensemble Precipitation	Diária e a cada 3 horas	0,1°x0,1° e 0,25°x0,25°	1979-2024
<b>CHIRPS</b>	Climate Hazards Group Infrared Precipitation with Station data	Diária	0,05°x0,05° e 0,25°x0,25°	1981-2024
<b>PERSIANN -CDR</b>	Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks-Climate Data Record	Diária	0,25°x0,25°	1983-2024
<b>PERSIANN -CCS-CDR</b>	Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks-Cloud Classification System-Climate Data Record	Diária	0,04°x0,04°	1983-2024

Fonte: Adaptado de Mianabadi (2023)

Quanto à origem dos dados, o MSEWP V2 é composto por uma combinação de dados medidos em campo, satélite e reanálise (Beck et al., 2019). O CHIRPS foi desenvolvido com base em estimativas de chuva de CCD (*Cold Cloud Duration*) calibradas pelo TMPA 3B42 v7 (*Tropical Rainfall Measuring Mission Multi-satellite Precipitation Analysis version 7*) (Huffman et al., 2006), e utiliza dados medidos em estações de campo para correção de viés. Já o PERSIANN-CDR é baseado no algoritmo PERSIANN-CDR (Hsu et al., 1997), usando dados do GridSat-B1 IRWIN Data (Knapp, 2008 *apud* Mianabadi, 2023, p. 3) para estimativa da precipitação e dados de campo do GPCP (Adler et al., 2003) para correção de viés (Nguyen et al., 2018), enquanto o PERSIANN-CCS-CDR é baseado nos algoritmos PERSIANN-CCS

(extrai feições das nuvens, incluindo geometria, temperatura e textura de imagens de satélite geoestacionárias em infravermelho (Hong et al., 2007)) e PERSIANN-CDR, combinados com informações de satélites GEO.

Diversos trabalhos avaliaram as estimativas de precipitação de diferentes produtos de sensoriamento remoto a fim de verificar a sua precisão em relação aos dados observados em campo. Ombadi et al. (2018) propuseram uma metodologia para o desenvolvimento de curvas IDF a partir de dados de satélite, incluindo correção de viés. Os pesquisadores aplicaram a metodologia proposta para definir curvas IDF a partir de dados de precipitação do PERSIANN-CDR e compará-las com curvas obtidas a partir de dados de estações de campo da National Oceanic and Atmospheric Administration (NOAA) Atlas 14, a fim de avaliar a precisão das estimativas. Venkatesh et al. (2021) desenvolveram uma proposta similar a partir de dados de precipitação do produto de satélite Global Precipitation Measurement (GPM-IMERG V6). Ambos os trabalhos indicaram que a correlação espacial entre os dados aumenta significativamente após a correção de viés. Além disso, uma porcentagem significativa das IDFs estimadas por dados de satélite se encontra dentro do intervalo de confiança dos dados de campo.

Com base na abordagem proposta por Ombadi et al. (2018) e Venkatesh et al. (2022), Mianabadi (2023) avaliou a performance de quatro produtos de sensoriamento remoto (MSWEP, CHIRPS, PERSIANN-CDR E PERSIANN-CCS-CDR), conforme Quadro 1, tanto individualmente, quanto em conjunto, para a determinação de curvas IF (Intensidade-Duração) para precipitação diária no Iran. As métricas estatísticas avaliadas mostraram que o CHIRPS obteve a melhor performance dentre os produtos avaliados e pode ser aplicado como fonte de dados alternativa para regiões não monitoradas. Além disso, as curvas IF produzidas a partir do conjunto dos produtos apresentou as estimativas mais precisas, e a performance dos produtos avaliados também melhorou significativamente após a correção de viés.

Xavier et al. (2021) avaliaram três produtos de satélite (CHIRPS V2, MSWEP V2 e PERSIANN-CDR) tendo como referência o produto gridBR para dados de média diária e extremos representados em escala mensal, e suas respectivas tendências sazonais de precipitação na bacia do Rio Mearim, no estado do Maranhão, Brasil. Os resultados mostraram que o CHIRPS e o PERSIANN-CDR obtiveram melhor performance para

representar a precipitação média diária mensal, especialmente em meses chuvosos, enquanto, para os extremos diários em escala mensal, o PERSIANN-CDR foi mais adequado. O uso do MSWEP para a região de estudo é desencorajado pelos autores porque superestima médias mensais e extremos.

Costa et al. (2019) verificaram a concordância dos dados mensais do produto CHIRPS com dados de estações meteorológicas do INMET em 183 pontos do território brasileiro e observaram uma determinação média de 97% considerando toda a área do Brasil. Paredes-Trejo et al. (2017) compararam a precipitação mensal estimada pelo CHIRPS com observações de campo em 21 estações do Nordeste brasileiro e o produto apresentou boa correlação com os dados de campo a nível mensal, mas tende a superestimar valores mais baixos e subestimar valores mais elevados de chuva. Observou-se também que o CHIRPS apresenta melhores resultados para o período chuvoso, mas sua capacidade de detecção de chuva é baixa. Além disso, o produto obteve melhor performance nas áreas do bioma Cerrado, mas apresentou baixa capacidade de detectar chuva nos outros biomas da região. Por fim, os autores concluíram que o produto pode ser um substituto adequado para dados de campo na região Nordeste apenas nas áreas fora do semiárido.

Silva et al. (2020) avaliaram como os dados de precipitação estimados pelo CHIRPS se comparam aos dados observacionais das estações meteorológicas do INMET e ANA, localizadas no município de Castanhal, estado do Pará, ao longo de um período de dezesseis anos, especificamente para a sub-bacia do rio Apeú. Em geral, os dados do CHIRPS mostraram uma tendência de superestimar a precipitação medida na região, especialmente durante o período chuvoso, embora tenham apresentado uma melhor concordância durante o período menos chuvoso. No entanto, os resultados indicaram que o CHIRPS conseguiu reproduzir de forma precisa a variabilidade sazonal da precipitação na área de estudo, demonstrando correlações significativas.

Bernardo et al. (2023) avaliaram o desempenho das estimativas do CHIRPS na representação de eventos de precipitação diária máxima anual, tendo como referência dados observados em 12 estações pluviométricas localizadas no município de Florianópolis-SC. Os autores encontraram correlação positiva entre os dados, mas na maioria dos pontos avaliados, o CHIRPS apresentou problemas de subestimativa dos eventos extremos em relação às observações *in situ*.

López-Bermeo et al. (2022) avaliaram a precisão do CHIRPS na sua representação da variabilidade climática em diferentes períodos de tempo. A pesquisa foi conduzida em Antioquia, no noroeste da Colômbia, e utiliza dados de 75 pluviômetros. Para avaliar de forma mais precisa o desempenho do CHIRPS na estimativa da precipitação em diferentes escalas de tempo, os autores realizaram uma comparação utilizando 12 pluviômetros específicos localizados em diferentes sub-regiões de Antioquia, que apresentam características climáticas distintas. Os resultados indicaram que a precisão das estimativas do CHIRPS é influenciada pelas características geográficas e climáticas da região em que ocorrem os eventos de precipitação. O CHIRPS apresentou bom desempenho na maioria das condições climáticas na área de estudo, mesmo durante os períodos mais intensos de ENOS. Contudo, sua performance foi superior nas sub-regiões andinas e inferior em regiões mais quentes. Os autores concluíram que o CHIRPS é uma fonte confiável de dados de precipitação para análises da variabilidade sazonal e interanual, bem como para identificação de padrões de precipitação espacial. Ele oferece uma boa cobertura espaço-temporal e é especialmente útil em áreas com poucos pluviômetros. No entanto, sua precisão é limitada para análises diárias.

### **3.3. Equações IDF**

As equações ou curvas IDF (Intensidade-Duração-Frequência) são normalmente utilizadas para estimar a frequência (ou período de retorno) de eventos de chuva observados e para gerar eventos de chuva sintéticos com determinada frequência, aplicados à projetos hidrológicos, hidráulicos e de sistemas de recursos hídricos, inclusive nas suas análises e validações. As curvas IDF são obtidas a partir da análise de frequências de precipitações observadas e descrevem a relação entre intensidade de chuva, duração de chuva e a sua probabilidade de excedência (Gnecco et al., 2023).

O método clássico para obter uma relação entre estas variáveis é através da análise de pluviogramas (Fendrich, 1998), pois estes possibilitam a obtenção dos eventos ocorridos nas diferentes durações como realizado por Bemfica et al. (2000), Freitas et al. (2001) e Silva et al. (2002). Diversos autores (Back et al., 2006; Garcia et al., 2011; Ghanmi et al., 2016; Oliveira et al., 2005; Silva et al., 2002) citam uma metodologia padronizada para determinar a equação IDF quando são utilizados registros

pluviográficos, que segue a seguinte sequência: (i) para cada duração são obtidas as precipitações máximas anuais, com base nos dados históricos; (ii) para cada duração mencionada é feita a análise de frequência e ajustada uma distribuição teórica de probabilidade que melhor represente a distribuição dos valores observados; (iii) dividindo a precipitação pela sua duração obtém-se a referida intensidade; (iv) plotando os resultados em formato gráfico são geradas as curvas IDF, que podem também ser expressas em forma de equação.

Pfafstetter (1957), através do Departamento Nacional de Obras de Saneamento (DNOS), publicou um estudo pioneiro sobre as chuvas intensas no Brasil. Este trabalho utilizou as séries de dados disponíveis em 98 postos pluviográficos espalhados pelo país para analisar a relação intensidade-duração-frequência de eventos de chuva, e até hoje é considerado uma referência no desenvolvimento de trabalhos que buscam atualizar as equações IDF de uma determinada região do país.

Silva et al. (2002) utilizaram 19 estações pluviográficas localizadas no Estado da Bahia e operadas pela Agência Nacional de Energia Elétrica (ANEEL) para analisar as relações intensidade-relação-frequência e estabelecer as respectivas equações IDF para essas localidades. Matos (2006) também determinou as equações de chuvas intensas para 28 postos pluviográficos espalhados pelo Estado da Bahia a partir de pluviogramas disponibilizados pelo Instituto Nacional de Meteorologia (INMET). O estudo contempla alguns municípios localizados na Região Sul da Bahia, sendo eles: Ilhéus, Canavieiras, Guaratinga e Caravelas.

Dada a importância da bacia do Rio Cachoeira para a Microrregião Ilhéus-Itabuna, inserida na Mesorregião Sul Baiano, bem como a necessidade de subsidiar os projetos hidráulicos numa região onde os eventos de inundação são frequentes, Ferraz et al. (2020b) estimaram os parâmetros da equação de chuvas intensas para 10 estações localizadas na bacia. Dentre os municípios contemplados no estudo estão: Lomanto Júnior, Floresta Azul, Ibicaraí, Santa Cruz da Vitória, Itaju do Colônia, Ilhéus, Itabuna, Itajuípe e São José. Na ausência de dados sub-diários, foram utilizados dados diários obtidos em pluviômetros, disponíveis no banco de dados da ANA, e para a desagregação da chuva em durações menores foram utilizados os coeficientes de desagregação da CETESB.

Devido à carência de curvas IDF atualizadas para muitas localidades do Estado da Bahia, se tornou uma prática comum dos projetistas a utilização de IDFs obtidas pelo software Plúvio 2.1 para a estimativa da vazão de projeto nos seus projetos hidráulicos. O Plúvio 2.1 foi desenvolvido pelo Grupo de Pesquisa em Recursos Hídricos (GPRH) da Universidade Federal de Viçosa (UFV) e disponibilizado em 2006 (GPRH, 2006). Este aplicativo utiliza um método de interpolação (inverso da quinta potência da distância) para determinação de equações IDF para qualquer coordenada inserida pelo usuário, a partir de localidades onde a equação IDF é conhecida. A maioria (19) das equações utilizadas como referência no software para o estado da Bahia foram determinadas por Silva et al. (2002), a partir de séries históricas de pluviógrafos com dados até 1999.

Fagundes et al. (2020) determinaram uma equação de chuvas intensas para o município de Gurupi-TO e compararam os seus resultados com uma equação fornecida pelo Plúvio 2.1 no dimensionamento de um bueiro retangular. As seções do bueiro apresentaram menores dimensões quando aplicada a equação proposta em relação à equação fornecida pelo software Plúvio 2.1. A intensidade da chuva de projeto calculada pela equação proposta foi 23% menor que a intensidade calculada pela equação fornecida pelo Plúvio 2.1. Os autores verificaram que a equação proposta resultou em uma estrutura mais robusta que a que se encontra construída na área estudada, a qual não possui capacidade de suporte para os volumes de chuva na sub-bacia. Além disso, favorece a otimização obra, uma vez que apresenta maior economia dos custos construtivos em relação à estrutura resultante da equação do Plúvio 2.1.

O estudo de Bragança et al. (2023) realizou uma comparação entre as vazões de projeto geradas pela equação IDF fornecida pelo Software Plúvio 2.1 e pela Subsecretaria de Gestão de Bacias Hidrográficas, Rio-Águas, na Bacia da Zona dos Canais, em Vargem Grande, RJ. Observou-se que as vazões de projeto calculadas pela Rio-Águas tendem a ser ligeiramente superiores em comparação com as obtidas pela Equação IDF do Plúvio. Segundo os autores, essas discrepâncias podem estar relacionadas às diferenças nos procedimentos de coleta e processamento de dados pluviométricos, bem como às características específicas da bacia de estudo. Por fim, concluiu-se que a modelagem do Plúvio é a mais próxima do valor previsto no Plano Municipal de Saneamento Básico da cidade do Rio de Janeiro.

Fiorio et al. (2012) compararam as alturas precipitadas geradas por equações IDF de referência com equações IDF fornecidas pelo Plúvio 2.1 para 30 localidades no estado de São Paulo. Os resultados revelaram que, principalmente para as chuvas de 24 horas e período de retorno de 100 anos, houve desvios importantes para 4 postos localizados na região central e a leste do Estado. Para as demais localidades o programa apresentou bom desempenho. Nascimento e Jesus (2017) também utilizaram o software Plúvio 2.1 para obter parâmetros da equação IDF para o município de Tucano-BA.

A determinação das equações IDF apresenta uma série de desafios, dentre eles estão: insuficiência de registros pluviográficos, baixa densidade da rede de pluviógrafos e curto período de observações disponível (Abreu et al., 2022; Aragão et al., 2024; Back, 2009; Back et al., 2012; Barbosa et al., 2022; F. Costa et al., 2024; Freitas et al., 2020; Nunes et al., 2021; Soares et al., 2016). Devido a essas e outras dificuldades, poucos trabalhos têm sido desenvolvidos nesta área, constituindo grande entrave na realização de projetos hidráulicos mais confiáveis e econômicos (Cecílio e Pruski, 2003; Melo e Silva 2013; Oliveira et al., 2005).

### **3.3.1. Método das relações de chuvas de diferentes durações**

Diversas metodologias alternativas foram desenvolvidas visando contornar as dificuldades mencionadas anteriormente, de modo a permitir a determinação das relações IDF a partir de dados diários de precipitação obtidos em pluviômetros. Segundo Presotto (2020), dentre os métodos disponíveis para estimar chuvas de menor duração a partir de uma de maior duração tem-se: o Método de Bell, o Método de Chen; o Método das Isozonas de Torrico, atualizado por Basso et al. (2016) e o Método das Relações de Chuvas de Diferentes Durações, sendo este último o mais amplamente utilizado no Brasil, por meio dos coeficientes de desagregação de chuvas propostos pela CETESB (1986), expostos na Tabela 2.

**Tabela 2 - Coeficientes de desagregação para diferentes durações de chuva**

<b>Relação entre alturas pluviométricas</b>	<b>Fator de desagregação</b>
24h / 1 dia	1,14
12h / 24h	0,85
10h / 24h	0,82
8h / 24h	0,78
6h / 24h	0,72
1h / 24h	0,42
30 min / 1h	0,74
25 min / 30 min	0,91
20 min / 30 min	0,81
15 min / 30 min	0,70
10 min / 30 min	0,54
5 min / 30 min	0,34

Fonte: CETESB (1986)

Vargas et al. (2015) analisaram a influência de coeficientes de desagregação diferentes na estimativa de intensidades de chuva no Rio Grande do Sul e observaram uma variação significativa entre os métodos utilizados, sendo o método proposto pela CETESB o mais satisfatório.

Back et al. (2012) determinaram as relações entre precipitações de diferentes durações para 13 estações pluviográficas do Estado de Santa Catarina e encontraram uma relação média entre a chuva de 24h e a chuva de 1 dia de 1,17, levemente superior ao coeficiente de 1,14 estimado pela CETESB. Os autores observaram que esta relação pode variar de 1,12 a 1,20 de acordo com o horário de leitura da precipitação diária. Além disso, encontraram valores significativamente inferiores aos recomendados pela CETESB para o coeficiente de 1h / 24h.

Presotto (2020) determinou coeficientes de desagregação da chuva diária para o Estado do Rio Grande do Sul e os comparou com os resultados obtidos em estudos anteriores para o estado e com os propostos pela CETESB (1986). Os resultados obtidos nesse estudo mostraram alguns coeficientes com diferenças de até 9,2%, quando comparados com médias obtidas por estudos anteriores, e diferenças que passam de 28% quando comparados com coeficientes da CETESB.

Abreu et al. (2022) analisaram a desagregação de chuva diária para estimar relações IDF em Minas Gerais e observaram uma diferença significativa entre as intensidades obtidas por registros de pluviógrafos e aqueles estimados por métodos de desagregação. Além disso, verificaram que a utilização de coeficientes específicos para a área de estudo resultou em estimativas mais precisas. Os autores concluíram ainda que os métodos de desagregação tendem a subestimar as intensidades, especialmente para longos tempos de retorno, o que pode ser prejudicial visto que esses estão associados a projetos que requerem maior segurança.

Matos (2006) determinou as percentagens dos totais precipitados em relação às diferentes durações para o Estado da Bahia. Dentre as 28 estações utilizadas no estudo, 4 estão localizadas na Mesorregião Sul Baiano – área de interesse do presente estudo – sendo elas: Canavieiras, Caravelas, Guaratinga e Ilhéus, consideradas pelo autor como inseridas na mesma Região Microclimática. Os valores encontrados para cada estação, bem como a média deles, foram comparados com a média obtida para toda a Bahia e com os valores do estudo do DAEE/CETESB (Tabela 3).

**Tabela 3 - Valores médios de precipitação em relação à chuva de 24h**

Posto	10 min	15 min	20 min	30 min	60 min	2h	4h	6h	10h	12h	24h	Período
Canavieiras	24,29	31,43	38,51	50,07	73,76	84,73	93,59	95,33	97,74	98,10	100	1985-1994
Caravelas	24,42	30,30	36,41	46,12	65,15	74,80	82,71	88,82	95,23	95,45	100	1985-1994
Guaratinga	30,88	41,56	47,86	58,26	66,13	78,38	87,61	89,41	93,10	97,06	100	1985-1994
Ilhéus	21,47	26,48	32,10	40,27	48,93	60,88	76,12	84,96	91,24	94,70	100	1985-1994
Média	25,27	32,44	38,72	48,68	63,49	74,70	85,01	89,63	94,33	96,33	100	1985-1994
Bahia	26,55	34,68	41,07	50,19	63,75	76,36	85,24	89,53	94,07	95,65	100	1985-1994
DAEE/CETESB	16,68	22,00	25,20	31,10	42,00			72,00		85,00	100	

Fonte: adaptado de Matos (2006)

**Tabela 4 - Relações médias de chuva encontradas por Matos (2006) e outros estudos**

t1	t2	BAHIA (85-94)	MAGNI	DNOS	WBUREAU	DENVER	GENOVEZ
30	5	0,30					
	10	0,50	0,51	0,54	0,57	0,63	0,49
	15	0,67	0,67	0,70	0,72	0,75	
	20	0,80	0,80	0,81		0,84	
60	30	0,73	0,74	0,74	0,79		0,78
1440	60	0,57	0,51	0,42			
	120	0,69					
	240	0,80					
	360	0,85	0,78	0,72			0,80
	600	0,89	0,85	0,82			
	720	0,91	0,88	0,85			0,89

Onde: t1 = duração base (min) e t2 = duração selecionada. Fonte: Matos (2006).

O estudo de Matos (2006) determinou também relações médias entre chuvas de diferentes durações para o Estado da Bahia e comparou com os resultados obtidos por outros estudos (Tabela 4).

### **3.4. Relações IDF sob a perspectiva de não estacionariedade**

Segundo Alexandre (2010), os sistemas de recursos hídricos são projetados tendo como premissa a estacionariedade estatística das séries de dados hidrológicos, de precipitação ou de vazão, ou seja, supõe-se que o comportamento dessas variáveis permanece constante ao longo do tempo. No entanto, tal premissa pode não ser verdadeira quando se leva em consideração fatores como a mudança de cobertura vegetal, variabilidade e mudança climática. Nesses casos, os projetos desenvolvidos com base na estacionariedade dos eventos hidrológicos devem ser revistos a fim de verificar o impacto dessas alterações no sistema hidráulico local.

Os modelos matemáticos que descrevem a maioria dos processos hidrológicos são chamados de sistemas estocásticos, visto que tais processos são regidos por princípios de probabilidade. De modo a simplificar a teoria matemática que envolve um processo estocástico, é comum assumir que o mesmo é estacionário. A estacionariedade representa o estado de equilíbrio de um processo estocástico, em outras palavras, as suas propriedades estatísticas não variam ao longo do tempo (Hipel e Mcleod, 1994). Segundo Naghettini e Pinto (2007), a não estacionariedade pode ser caracterizada em três tipos: saltos, ciclos e tendências. A primeira se trata das alterações bruscas em um corpo hídrico, como a construção de uma barragem. A segunda está associada às flutuações climáticas e é de difícil detecção. Por fim, as tendências estão relacionadas às alterações graduais que ocorrem na bacia, como por exemplo um processo de urbanização crescente.

Segundo Yilmaz et al. (2014), o aumento na frequência e magnitude de eventos de precipitação extrema atribuído às mudanças climáticas, e a variabilidade climática decadal e multi-decadal questionam a premissa de estacionariedade climática. A possibilidade de violação da estacionariedade no clima pode resultar em estimativas errôneas de chuvas de projeto baseadas em análise de frequência de chuvas intensas. Isto pode resultar em consequências significativas para projetos de drenagem urbana visto que a chuva de projeto é um elemento essencial no dimensionamento dessas estruturas. Sendo assim, há uma necessidade de conduzir

análises de frequência de eventos de chuvas extremas no contexto de não estacionariedade, quando essa condição se confirmar.

Ribeiro et al. (2019) analisaram a estacionariedade de séries hidrológicas de chuva e vazão (1945 a 2017) da bacia de contribuição da UHE Castro Alves, no Estado do Rio Grande do Sul e concluíram que as séries analisadas são não estacionárias, ocorrendo uma mudança de comportamento a partir do ano de 1970, apresentando um aumento significativo em relação ao período anterior.

Além da mudança no uso e cobertura do solo e da variabilidade natural nos padrões de precipitação, observa-se uma potencialização desses efeitos decorrente das mudanças climáticas, que são fenômenos globais de um sistema climático em constante mudança que representa perigo ao meio ambiente, às espécies e à subsistência de organismos vivos na Terra. A emissão de gases de efeito-estufa produzidos por atividades antrópicas como a queima de combustíveis fósseis, desmatamento e uso excessivo de fertilizantes são os principais fatores das mudanças climáticas. Tais mudanças causam inevitavelmente alterações nas características e variações das séries de precipitação, o que aumenta a dificuldade de previsão das chuvas (Galavi et al. 2019; Galavi e Mirzaei 2020).

De forma a projetar as respostas climáticas às futuras mudanças no clima e socioeconômicas, o IPCC (2021) determina cinco cenários de projeção de concentração de gases de efeito estufa na atmosfera, considerando não apenas a emissão desses gases, mas também os possíveis futuros de desenvolvimento antropogênico, como questões socioeconômicas, nível de mitigação de mudança climático atingido e controle da poluição do ar. A aplicação desses cenários em modelos climáticos permite a simulação de séries projetadas de precipitação, que são importantes ferramentas para estudos que abordam adaptação às mudanças climáticas.

Hosseinzadehtalaei et al. (2020) desenvolveram curvas IDF a partir de chuvas observadas e projetadas para durações de 30 min, 1h, 3h, 6h, 12h e 24h e tempos de retorno variando de 1 a 100 anos. As curvas IDF futuras foram determinadas a partir da aplicação de cenários de projeção climática de um modelo climático regional a curvas IDF atuais, obtidas com base em produtos de sensoriamento remoto de alta resolução. Os autores analisaram as mudanças observadas nas curvas e os

resultados mostraram uma elevação de 16-27% nas curvas e um aumento na inclinação de 17-25%, indicando a vulnerabilidade das infraestruturas hidráulicas atuais.

Schardong et al. (2014) atualizaram a equação IDF oficialmente utilizada pela prefeitura da cidade de São Paulo em seus projetos de infraestrutura hidráulica, considerando cenários de projeção climática e observaram perspectiva de aumento dos eventos extremos de 4,5% (cenários de menor emissão) até mais de 30% (cenários de alta emissão), indicando que estruturas projetadas com base em dados históricos podem ser comprometidas com o passar dos anos.

S. Maity e R. Maity (2022) investigaram alterações espaço-temporais nas relações IDF envolvendo eventos horários de precipitação para clima passado e futuro na Índia e observaram que quase toda a extensão do território indiano poderá apresentar aumento na intensidade de precipitação horária de 19% (cenário otimista) até 44% (cenário pessimista).

#### **3.4.1. Identificação de tendência em séries temporais**

De modo a verificar a condição de não estacionariedade de uma série temporal, são utilizados testes estatísticos para detecção de tendências, os quais podem ser classificados como paramétricos ou não-paramétricos, segundo Naghettini e Pinto (2007). Os testes paramétricos assumem que os dados de séries temporais seguem uma distribuição específica (geralmente, a distribuição normal) e são capazes de quantificar as mudanças observadas nas séries. Já os testes não-paramétricos não seguem uma determinada distribuição e detectam tendências nas séries, mas não buscam quantificar a magnitude das mudanças. Maior atenção é dada a estes mencionados por último uma vez que a maioria das séries temporais de dados hidrológicos não apresenta distribuição normal.

Os testes estatísticos mais utilizados para verificar a significância de mudanças graduais na série de dados hidrológicos são os testes não-paramétricos de Mann-Kendall, de Spearman (Villarini et al., 2009b; Villarini et al., 2011) e de Kendall Sazonal, e o teste paramétrico de regressão linear (Toffol et al., 2009), que testa se há uma tendência linear verificando a relação entre o tempo e a variável de interesse.

Além dos testes de tendência, outros testes importantes para a detecção de mudanças em séries de dados hidrológicos são os testes de mudanças abruptas, que verificam a significância da mudança do valor central da amostra a partir de um ponto da série conhecido ou não. Dentro desta abordagem, de acordo com Nunes (2018), os principais testes utilizados são: a soma acumulada não paramétrica ou *Distribution-Free CUSUM* (não-paramétrico), desvio acumulado ou *Cumulative Deviation* (paramétrico), teste da razão de verossimilhança de Worsley ou *Worsley Likelihood Ratio* (paramétrico), soma das ordens ou *RankSum* (não paramétrico) e o teste convencional de *Student* (paramétrico).

No que se refere a aplicação desses testes, Nunes et al. (2021) buscaram identificar possíveis tendências nas intensidades máximas de precipitação em Belo Horizonte (MG) e propor, com base nos resultados obtidos, uma nova curva de intensidade-duração-frequência (IDF) que leve em conta essa não estacionariedade. Para isso, utilizaram o teste de Mann-Kendall para avaliar alterações graduais nas séries e os testes de *Distribution-Free CUSUM* e *Rank Sum* para identificar mudanças abruptas. Como resultado, identificaram diferentes padrões de tendência, com um aumento nas intensidades de chuva para durações de até 1 hora a partir do ano 2000. A respeito das relações IDF, observaram que as intensidades de chuva obtidas foram significativamente maiores do que as estimativas atuais, chegando a ser até 48% superiores

Segundo Nunes (2018), é comum verificar as tendências através da análise de séries históricas de precipitação. No entanto, para uma conexão mais eficaz entre a análise de tendências e a detecção de mudanças climáticas, a Organização Meteorológica Mundial (OMM) desenvolveu uma série de índices por meio de um grupo de especialistas chamado "Expert Team on Climate Change Detection Monitoring and Indices - ETCCDMI". Esses índices são úteis na detecção de tais mudanças e incluem um total de 27 principais, dos quais 16 estão relacionados à temperatura e 11 à precipitação. Os índices de precipitação são os seguintes:

- CDD: Número anual de dias secos consecutivos
- CWD: Número anual de dias chuvosos consecutivos
- Sdii: Índice de intensidade diária
- Rx1d: Precipitação máxima mensal em 1 dia

- Rx5d: Precipitação máxima mensal em 5 dias consecutivos
- R10mm: Número anual de dias chuvosos acima de 10 mm
- R20mm: Número anual de dias chuvosos acima de 20 mm
- R30mm: Número anual de dias chuvosos acima 30 mm
- R95p: dias muito chuvosos
- R99p: Dias extremamente chuvosos
- PRCPTOT: Total anual de dias chuvosos

No que diz respeito à exploração desses índices, Queiroz (2013) examinou as tendências das séries de precipitação diária máxima anual na região central do estado de Minas Gerais. Ele utilizou índices de precipitação que podem ser úteis para identificar mudanças climáticas. Ficou evidenciado que os índices de dias extremamente chuvosos (R99p), número de dias com precipitações acima de 30 mm (R30mm), quantidade máxima de precipitação em 5 dias (Rx5day) e o índice de intensidade diária (Sdii) apresentaram tendências significativas, sendo predominante a tendência positiva.

Nunes et al. (2018) também alisaram as tendências dos eventos de precipitação extrema na Região Metropolitana de Belo Horizonte, com foco especial em sua frequência, utilizando índices estabelecidos pelo ETCCDMI. Embora não foi identificado um padrão regional claro com base nessas análises, os autores observaram um aumento estatisticamente significativo nos eventos de precipitação diária em Belo Horizonte, com valores acima de 10, 20, 30 e 40 mm, bem como na precipitação máxima registrada em cinco dias consecutivos, na intensidade diária e na precipitação anual total. Além disso, notaram mudanças abruptas nas séries de precipitação ao longo do tempo.

Sendo assim, quando os testes estatísticos citados anteriormente são aplicados nas séries hidrológicas e a condição de estacionariedade não é verificada, a análise de frequência requer a aplicação de métodos adequados para esta condição, uma vez que os parâmetros distributivos são variáveis no tempo e, conseqüentemente, as probabilidades de excedência dos quantis de referência também estão propensas a mudanças (Clarke, 2007; Obeysekera e Salas, 2014).

### 3.4.2. Análise de frequência sob a hipótese de não estacionariedade

Quando as séries hidrológicas mostram características que não seguem a premissa de estacionariedade - avaliada previamente por meio de testes estatísticos, como o teste de Mann-Kendall - então é necessário usar métodos apropriados para analisar a frequência, pois os parâmetros distributivos variam (Wi et al., 2016). Nesse contexto, que se concentra no estudo dos máximos anuais, é possível aplicar o método de distribuição de Valores Extremos Generalizados (GEV) (Coles, 2001). Neste caso, levando em conta a condição de não estacionariedade, os parâmetros da distribuição serão variáveis ao longo do tempo (anos).

Dentro do âmbito da análise de frequência considerando a não estacionariedade, alguns conceitos fundamentais, que são aplicáveis sob a premissa de estacionariedade, não se aplicam diretamente à análise não estacionária, como é o caso do tempo de retorno (TR). Nesse contexto, diversos estudos têm colaborado para expandir esses conceitos, visando adaptá-los para cenários de não estacionariedade. Um exemplo notável é o conceito introduzido por Rootzén e Katz (2013), chamado *Design Life Level* (DLL). Esse conceito leva em conta o período de vida útil de uma determinada estrutura projetada e a probabilidade de ocorrência de um evento extremo durante esse período. Em outras palavras, ele determina um quantil associado a uma probabilidade de que esse evento seja excedido pelo menos uma vez durante a vida útil da estrutura projetada.

No mesmo estudo mencionado anteriormente, Rootzén e Katz (2013) introduziram também o conceito "*Minimax Design Life Level: the  $T_1$ - $T_2$   $p\%$  bounded yearly risk level*". O Design Life Level é empregado como uma métrica para avaliar o risco em projetos de engenharia, especialmente em contextos de não estacionariedade. Seu objetivo é alcançar uma probabilidade específica de ocorrência de eventos perigosos (ou falhas) ao longo da vida útil do projeto. Por outro lado, o Minimax Design Life Level, embora relacionado, é uma abordagem complementar. Ele se concentra na probabilidade máxima anual de ocorrência de eventos durante o período de vida útil do projeto (Nunes, 2018).

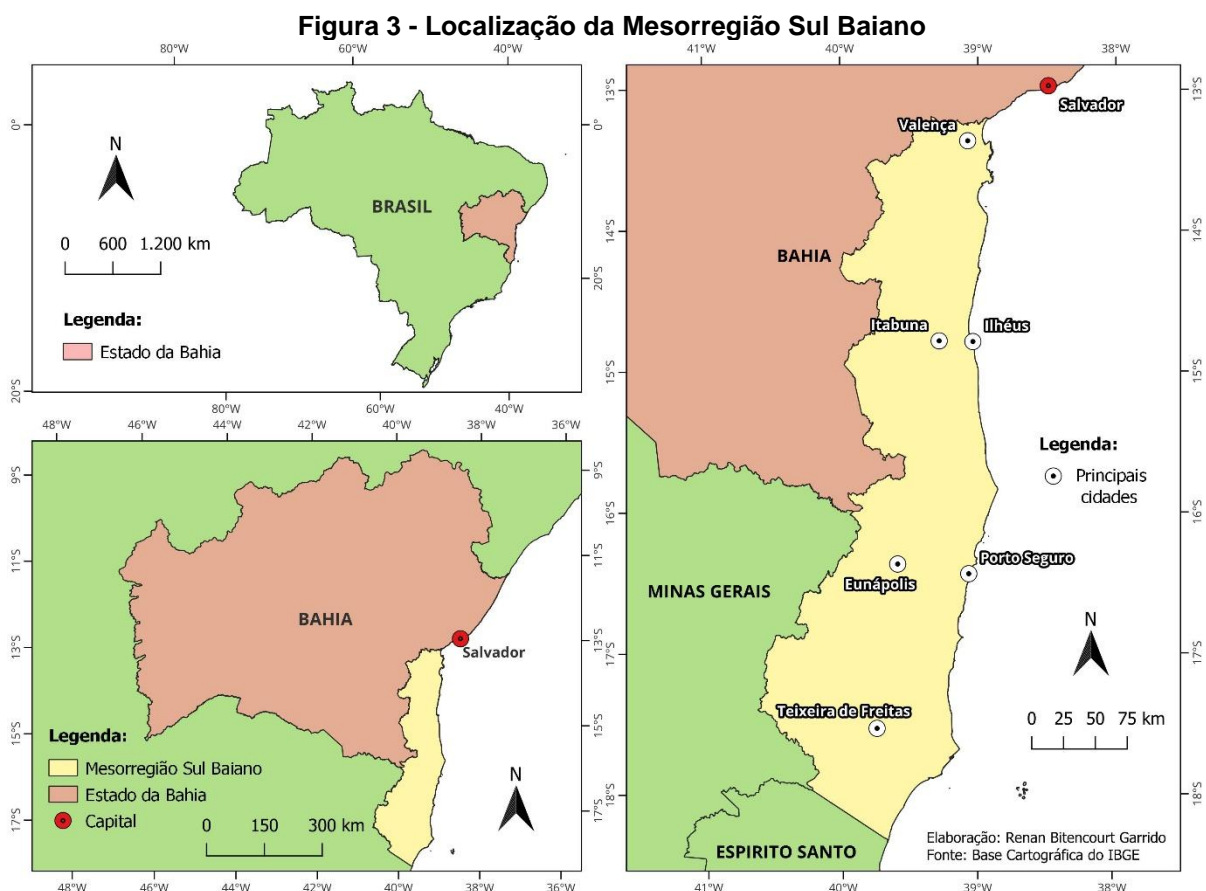
No Brasil, Moreira et al. (2016) aplicaram essa metodologia com o intuito de examinar o risco de precipitação para duração de dez dias, na região de Tarauacá, no estado do Acre. Por outro lado, Nunes et al. (2021) propuseram uma adaptação do conceito

"*Minimax Design Life Level: the  $T_1$ - $T_2$  p% bounded yearly risk level*", para avaliar as magnitudes das precipitações com vistas a aplicações em projetos de engenharia diante de cenários de não-estacionariedade das séries temporais.

## 4. MATERIAIS E MÉTODOS

### 4.1. Área de estudo

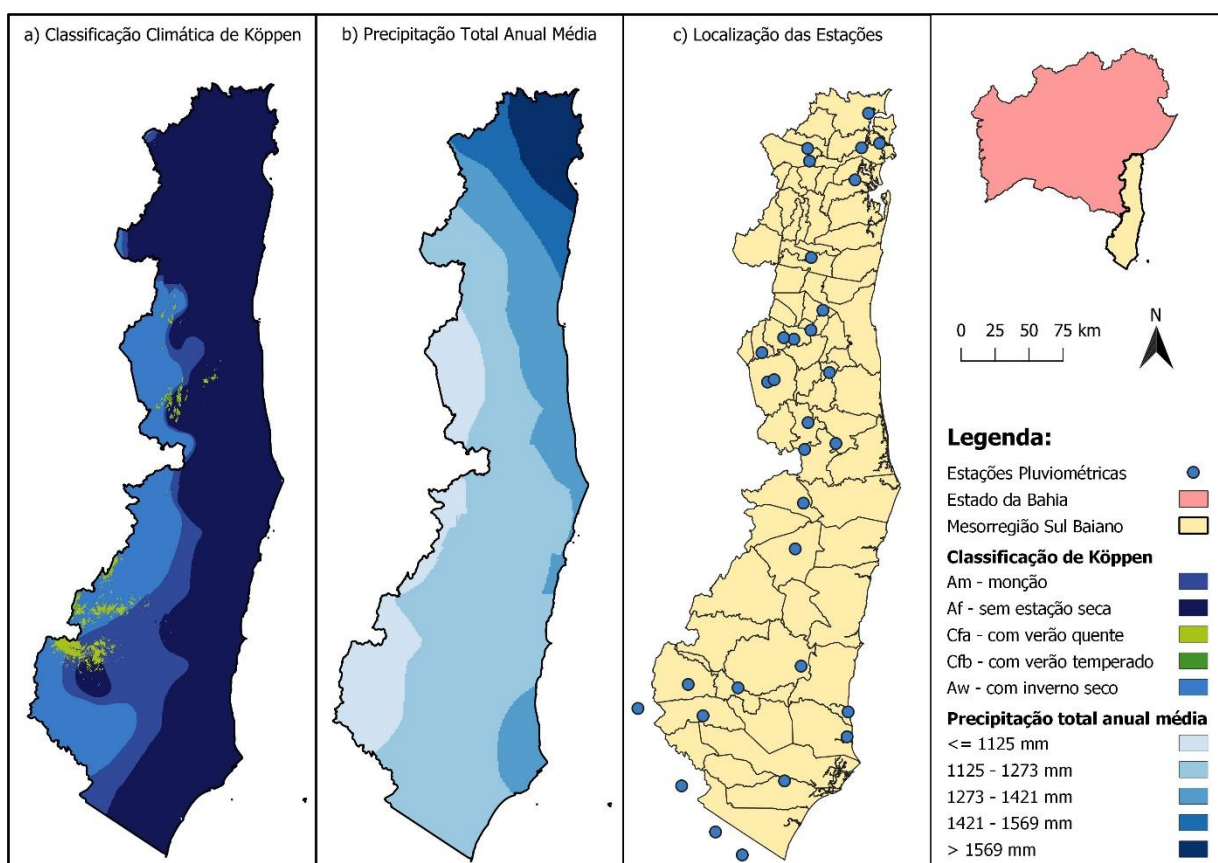
O Estado da Bahia, localizado no Nordeste do Brasil, está dividido em sete mesorregiões, conforme regionalização de 1989/90 do IBGE, sendo elas: Extremo Oeste Baiano, Vale São-Franciscano da Bahia, Centro Norte Baiano, Nordeste Baiano, Metropolitana de Salvador, Centro Sul Baiano e Sul Baiano. Esse estado também está subdividido em 32 microrregiões geográficas. As Microrregiões Ilhéus-Itabuna, Valença e Porto Seguro compõem a Mesorregião Sul Baiano (Aguiar, 2018). A Mesorregião Sul Baiano (Figura 3) enfrenta historicamente consequências de eventos de chuvas intensas, que trazem impactos significativos na região e têm se tornado cada vez mais frequentes. Nos últimos anos o estado da Bahia vivenciou episódios extremos, que ocorreram nos anos de 2021, 2022 e 2023, e resultaram em diversos pontos de inundações, vítimas fatais, famílias desabrigadas e decretos de situação de emergência em diversos municípios no sul do estado. Em 2021, 24 pessoas morreram e 629 mil foram afetadas em toda a Bahia (G1 Bahia e TV Santa Cruz, 2022).



Fonte: Autor.

Esta mesorregião abrange 70 municípios, possui uma área aproximada de 54.685,580 km<sup>2</sup> e uma população estimada de 2.100.238 habitantes (IBGE, 2024). Segundo a classificação de Köppen para o Brasil (Alvarez et al., 2013), o tipo climático predominante na área é o Tropical de Floresta (Af), com precipitações anuais entre 1900 a 2000 mm. Este tipo climático é caracterizado pela ausência de estação seca, com precipitações maiores que 60 mm no mês mais seco e maior volume de chuvas entre os meses de março e agosto (Ferraz et al., 2020a). Além do clima Af, que abrange a área costeira a leste, a região possui outros dois domínios climáticos variando no sentido leste-oeste: o clima tropical de monções (Am) na porção central e o clima tropical subúmido com chuvas no verão e períodos de seca no inverno (Aw) na porção oeste (Engelbrecht et al., 2019) (Figura 4).

**Figura 4 - Mapas de classificação climática (a), precipitação total anual média (b) e localização das estações utilizadas (c)**



Fonte: Autor.

Mais informações sobre as estações utilizadas podem ser encontradas no item 4.3.

## 4.2. Procedimentos metodológicos

O Quadro 2 apresenta os objetivos específicos da pesquisa, as atividades e as respectivas técnicas previstas e fontes de informação necessárias para atingir cada um deles. Cada etapa do trabalho é descrita de forma mais detalhada nos tópicos seguintes.

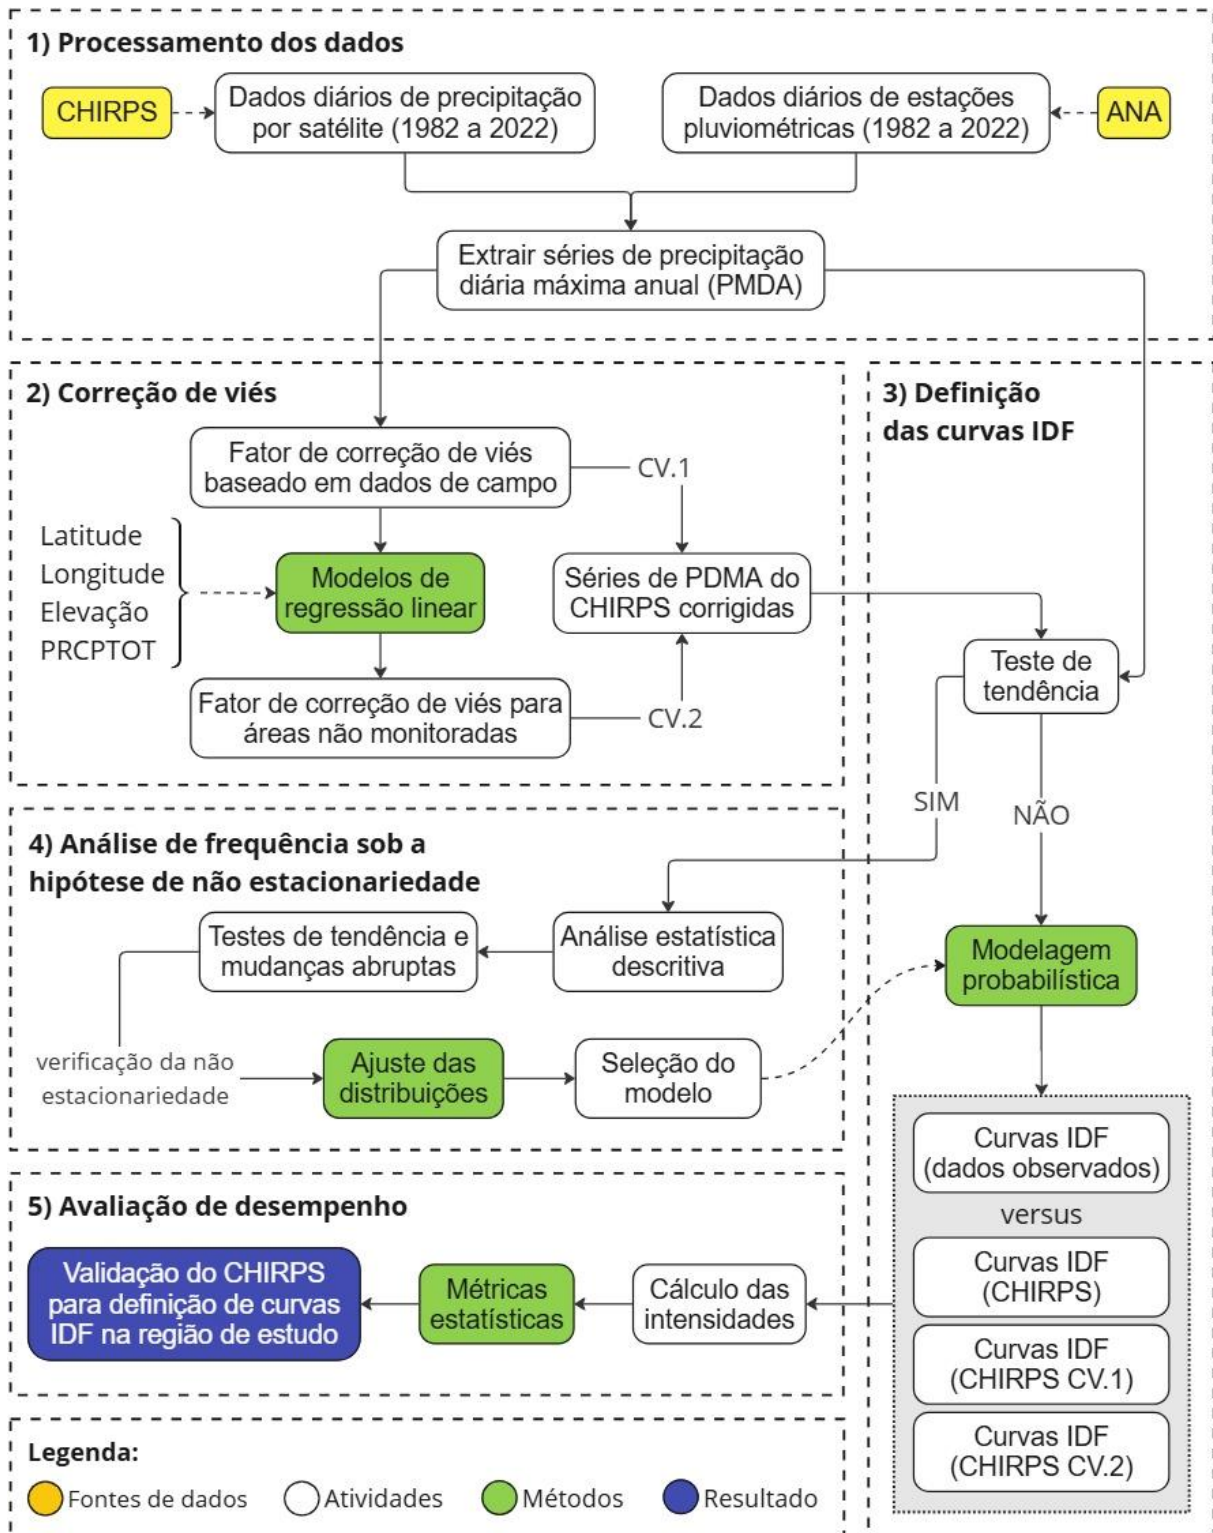
**Quadro 2 - Sistematização dos procedimentos realizados**

<b>Objetivos específicos</b>	<b>Atividades</b>	<b>Técnicas utilizadas</b>	<b>Fontes de dados</b>
Avaliar o desempenho de estimativas de precipitação por satélite na determinação de relações IDF na região de estudo	<ul style="list-style-type: none"><li>• Levantar dados de precipitação <i>in situ</i></li><li>• Obter e validar estimativas de precipitação por satélite</li><li>• Determinar curvas IDF</li><li>• Comparar as curvas IDF propostas com curvas IDF de referência</li></ul>	<ul style="list-style-type: none"><li>• Métricas estatísticas</li><li>• FDP</li></ul>	<ul style="list-style-type: none"><li>• CHIRPS</li><li>• ANA</li></ul>
Avaliar a aplicabilidade das estimativas de precipitação por satélite em áreas não monitoradas da região de estudo	<ul style="list-style-type: none"><li>• Calcular fator de correção de viés</li><li>• Propor correção de viés para áreas não monitoradas</li></ul>	<ul style="list-style-type: none"><li>• Métricas estatísticas</li><li>• FDP</li><li>• Regressão linear</li></ul>	<ul style="list-style-type: none"><li>• CHIRPS</li><li>• ANA</li></ul>
Analisar as séries temporais de precipitação na região de estudo sob a ótica de não estacionariedade	<ul style="list-style-type: none"><li>• Analisar tendências nas séries temporais</li><li>• Análise de frequência para séries não estacionárias</li></ul>	<ul style="list-style-type: none"><li>• Testes estatísticos</li><li>• FDP</li></ul>	<ul style="list-style-type: none"><li>• ANA</li></ul>

Fonte: Autor.

A Figura 5 apresenta o fluxograma metodológico da pesquisa, identificando as atividades realizadas, as técnicas utilizadas e as fontes de dados necessárias para atingir os objetivos.

Figura 5 - Fluxograma metodológico da pesquisa



Fonte: Autor

#### 4.3. Dados de precipitação observados *in situ*

Foram utilizadas 31 estações pluviométricas com dados de precipitação diária localizadas na área de estudo, disponíveis na plataforma Hidroweb da Agência

Nacional de Águas e Saneamento Básico (ANA). Foram selecionadas estações com maior disponibilidade de dados e cobertura temporal compatível com os dados de precipitação estimados por satélite. Apenas estações com menos de 10% de falhas foram consideradas. De acordo com a disponibilidade temporal do CHIRPS, foram analisados dados de 1982 a 2022 (41 anos). As informações de cada estação utilizada estão apresentadas no Quadro 7, no APÊNDICE A.

#### **4.4. Dados de precipitação estimados por satélite**

Um dos produtos de satélite disponíveis e amplamente utilizados em estudos climáticos ultimamente é o CHIRPS (*Climate Hazards Group InfraRed Precipitation with Stations*), que é um conjunto de dados desenvolvidos pelo United States Geological Survey (USGS) e pelo Climate Hazards Group at the University of California, Santa Barbara (UCSB). Este produto foi desenvolvido com base em estimativas de chuva de CCD (*Cold Cloud Duration*) calibradas pelo TMPA 3B42 v7 (*Tropical Rainfall Measuring Mission Multi-satellite Precipitation Analysis version 7*), utiliza dados medidos em estações de campo para correção de viés e disponibiliza dados de precipitação diária nas resoluções de  $0,05^{\circ} \times 0,05^{\circ}$  e  $0,25^{\circ} \times 0,25^{\circ}$  com cobertura temporal de 1981 até os dias atuais (Funk et al., 2015).

O CHIRPS foi selecionado para este estudo devido a sua extensa cobertura temporal, alta resolução espacial e, principalmente, por apresentar bom desempenho quando comparado a outros produtos (Mianabadi, 2023), inclusive em regiões tropicais da América do Sul (J. Costa et al., 2019; López-Bermeo et al., 2022; Paredes-Trejo et al., 2017; Xavier et al., 2021;).

Os dados do CHIRPS estão disponíveis no sítio eletrônico da UCSB (<ftp://ftp.chg.ucsb.edu/pub/org/chg/products/CHIRPS-2.0/>), em formato NetCDF, GeoTiff e Esri BIL. Para extração dos dados pontuais correspondentes à localização das estações pluviométricas disponíveis no banco de dados da ANA, foi utilizado código em linguagem R, processados no Rstudio.

O Quadro 3 apresenta o resumo dos dados de precipitação que serão utilizados na pesquisa, com suas respectivas fontes, escala temporal e disponibilidade de dados. Em relação aos dados do Hidroweb, há uma grande variabilidade em relação à

disponibilidade das séries históricas de cada estação, devido à interrupção do monitoramento e até mesmo encerramento da operação de alguns pluviômetros.

**Quadro 3 – Resumo dos dados utilizados na pesquisa**

Variável	Fonte	Escala temporal	Disponibilidade
Precipitação (pluviômetros)	ANA	Diária	Até 2023
Precipitação (satélite)	CHIRPS	Diária	1981 - 2024

Fonte: Autor

#### **4.5. Avaliação do CHIRPS para determinação de curvas IDF na área de estudo**

Nesta etapa buscou-se validar a utilização de dados de precipitação obtidos por satélite de modo a contornar a baixa disponibilidade espacial de dados de campo na área de estudo. Para que os dados de precipitação por satélite sejam utilizados, é necessário verificar a precisão das suas estimativas. Para isso, foram desenvolvidas curvas IDF a partir de dados do CHIRPS e comparadas com curvas desenvolvidas com dados de campo.

##### **4.5.1. Determinação das curvas IDF**

Para determinação das curvas IDF foi utilizada a ferramenta *Genetic Algorithm Methodology for IDF* (GAM-IDF), desenvolvida pelo Grupo de Pesquisa em Hidrologia e Modelagem Hidrológica em Bacias Hidrográficas da Universidade Federal de Pelotas (UFPel) (Cunha et al., 2019; Vargas et al., 2019). A ferramenta permite importar o arquivo padrão do Hidroweb, em formato .csv, e a partir dos dados diários, o algoritmo executa todo o processamento necessário para obtenção das séries de PMDA, considerando anos válidos aqueles que possuem no máximo 31 dias de falhas e utilizando prioritariamente dados de chuva consistidos. Os anos com falha são representados na série por “NA”. De forma alternativa, o usuário pode inserir a série de PMDA nos formatos .csv, .txt ou .xls e nenhum processamento dos dados de entrada é realizado. Além disso, o algoritmo verifica a existência ou não de tendência na série de dados a partir da aplicação do teste não-paramétrico de Mann-Kendall (Mann, 1945; Kendall, 1975) ao nível de significância de 5%. Das trinta e uma estações testadas, quatro séries de dados observados em campo apresentaram tendência, enquanto apenas uma série estimada pelo CHIRPS apresentou, impossibilitando a construção de curvas IDF a partir dessas séries, considerando a

premissa de estacionariedade. Portanto, das trinta e uma estações iniciais, apenas vinte e seis foram utilizadas para definição das curvas. A estações que apresentaram tendência foram posteriormente analisadas sob a ótica da não estacionariedade a partir de uma análise estatística mais aprofundada.

**Quadro 4 - Funções densidade de probabilidade (FDPs) disponíveis para modelagem probabilística no GAM-IDF**

Distribuição	Cód	Número de Parâmetros	Parâmetros	F(x)
Exponencial	EXP	2	$\xi \alpha$	$F = 1 - e^{-\frac{(x-\xi)}{\alpha}}$
Gamma	GAM	2	$\alpha \beta$	$F = G\left(\frac{x}{\beta}, \alpha\right)$
Generalizada de Valores Extremos	GEV	3	$\xi \alpha k$	$F = e^{\left[-\left(\frac{1-k(x-\xi)}{\alpha}\right)^{\frac{1}{k}}\right]}$
Logística Generalizada	GLO	3	$\xi \alpha k$	$F = \frac{1}{\left[1 + \left\{\frac{1-k(x-\xi)}{\alpha}\right\}^{\frac{1}{k}}\right]}$
Normal Generalizada	GNO	3	$\xi \alpha k$	$F = \Phi\left[-k^{-1} \log\left\{1 - \frac{k(x-\xi)}{\alpha}\right\}\right]$
Generalizada de Pareto	GPA	3	$\xi \alpha k$	$F = 1 - \left\{1 - \frac{k(x-\xi)}{\alpha}\right\}^{\frac{1}{k}}$
Gumbel	GUM	2	$\xi \alpha$	$F = e^{\left[-e^{\left\{-\frac{(x-\xi)}{\alpha}\right\}}\right]}$
Kappa	KAP	4	$\xi \alpha k h$	$F = \left[1 - h\left\{1 - \frac{k(x-\xi)}{\alpha}\right\}^{\frac{1}{k}}\right]^{\frac{1}{h}}$
Pearson tipo III	PT3	3	$\mu \sigma \gamma$	$F = G\left(\left(x - \mu + \frac{2\sigma}{\gamma}\right) \left \frac{1}{2}\sigma\gamma\right , \frac{4}{\gamma^2}\right), \gamma > 0$ $F = 1 - G\left(-\left(x - \mu + \frac{2\sigma}{\gamma}\right) \left \frac{1}{2}\sigma\gamma\right , \frac{4}{\gamma^2}\right), \gamma < 0$
Wakeby	WAK	5	$\xi \alpha \beta \gamma \delta$	Não definido explicitamente
Log-Normal 3 parâmetros	LN3	3	$\xi \mu \sigma$	$F = \Phi\left(\frac{\{\log(x-\xi) - \mu\}}{\sigma}\right)$
Weibull	WEI	3	$\zeta \beta \delta$	$F = 1 - e^{\left[-\left(\frac{x-\zeta}{\beta}\right)^{\delta}\right]}$

Fonte: Hosking (2024).

Após a obtenção da série de PMDA, é realizada a modelagem probabilística. Nesta etapa, o algoritmo irá ajustar diversas funções densidade de probabilidade (FDPs) à série de PMDA e comparar a qualidade dos ajustes com base em teste de aderência, escolhendo a melhor. São disponibilizadas doze FDPs que são frequentemente empregadas em análises de chuvas intensas (Caldeira et al., 2015a; Beskow et al., 2015), desde FDPs mais simples (Gumbel, Exponencial, Gama) até FDPs multiparâmetros (Kappa, Wakeby), listadas no Quadro 4. Os parâmetros de todas as FDPs são estimados pela técnica dos momentos-L (Hosking e Wallis, 1997). Ressalta-se que o teste aderência empregado é o de Anderson-Darling, ao nível de significância

de 5%, pois é um teste robusto para avaliação de ajuste de FDPs a séries de chuva máxima diária anual (Beskow et al., 2015).

Os tempos de retorno considerados no ajuste das equações IDF foram de 2, 5, 10, 20, 50 e 100 anos. O próximo passo foi a desagregação da precipitação máxima diária anual associada a cada TR. A ferramenta utiliza o método das relações das durações para estimar a precipitação em escala sub-diária. Foram utilizadas as constantes de desagregação da CETESB (1986) (Quadro 5), visto que são usualmente empregadas no Brasil para desagregação de chuvas diárias (Caldeira et al., 2015b) na ausência de coeficientes de desagregação locais. As alturas pluviométricas (h) desagregadas, associadas a diferentes TRs e durações, são convertidas em intensidade de chuva ( $\text{mm.h}^{-1}$ ).

**Quadro 5 - Coeficientes de desagregação para diferentes durações utilizados pelo GAM-IDF**

Relação de durações	$h_{24}/h_{\text{dia}}$	$h_6/h_{24}$	$h_1/h_{24}$	$h_{30}/h_1$	$h_{20}/h_{30'}$	$h_{15}/h_{30'}$	$h_{10}/h_{30'}$	$h_5/h_{30'}$
Coeficientes de desagregação	1,14	0,72	0,42	0,74	0,81	0,70	0,54	0,34

Fonte: CETESB (1986)

Realizados todos os processamentos, a ferramenta ajusta os parâmetros *a*, *b*, *c* e *d* do modelo matemático (Equação 1) que faz a relação entre a intensidade da chuva ( $\text{mm.h}^{-1}$ ), sua duração (horas) e o tempo de retorno (anos). Para ajuste desses parâmetros, é utilizado o algoritmo genético *Shuffled Complex Evolution – University of Arizona* (SCE-UA) (Duan et al., 1992), tendo como função objetivo o coeficiente de Nash e Sutcliffe (1970) (NSE). O NSE varia de  $-\infty$  a 1, e quanto mais próximo de 1, melhor o ajuste.

$$I = \frac{aTR^b}{(c + t)^d}$$

**Equação 1**

Onde *I* = intensidade de precipitação ( $\text{mm.h}^{-1}$ ), *t* = duração da chuva (minutos), *TR* = tempo de retorno (anos), enquanto *a*, *b*, *c* e *d* são os parâmetros da IDF.

Com os parâmetros das equações IDF obtidos, calculou-se as intensidades (*i*) para diferentes períodos de retorno (2, 5, 10, 15, 20 e 25 anos) e considerando um tempo de duração (*d*) de 10 minutos. Essa escolha foi feita pensando em analisar a aplicação das curvas IDF para obras de microdrenagem.

#### 4.5.2. Validação das curvas IDF geradas pelos dados de satélite

Em busca de um método robusto para avaliar a precisão das estimativas dos produtos de satélite em relação aos dados observados, diversos estudos aplicaram uma combinação de ao menos quatro métrica estatísticas (F. Costa et al., 2024; J. Costa et al., 2019; López-Bermeo et al., 2022; Mianabadi, 2023; Ramos Filho et al., 2022; E. Silva et al., 2020; Venkatesh et al., 2022; Xavier et al., 2021). Assim, para avaliação da performance das curvas IDF estimadas pelo CHIRPS, foram adotadas quatro métricas estatísticas descritivas (Quadro 6), sendo estas: Erro Percentual Médio (PBIAS), Raíz do Erro Quadrático Médio (RMSE), Erro Absoluto Médio (MAE) e o Coeficiente de Nash e Sutcliffe (NSE).

**Quadro 6 - Métricas estatísticas utilizadas na avaliação**

Coeficiente	Definição	Fórmula	Faixa de valores	Valor ideal
PBIAS	Erro Percentual Médio	$PBIAS = 100 \frac{\sum_{i=1}^n (S_i - O_i)}{\sum_{i=1}^n (O_i)}$	$-\infty$ a $+\infty$	0
RMSE	Raíz do Erro Quadrático Médio	$RMSE = \left[ \frac{1}{n} \sum_{i=1}^n (S_i - O_i)^2 \right]^{1/2}$	0 a $+\infty$	0
MAE	Erro Absoluto Médio	$MAE = \frac{1}{N} \sum_{i=1}^n  S_i - O_i $	0 a $+\infty$	0
NSE	Coeficiente de eficiência de Nash-Sutcliffe	$NSE = 1 - \frac{\sum_{i=1}^n (S_i - O_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2}$	$-\infty$ a 1	1

Onde: S = valores dos dados estimados pelo CHIRPS; O = dados observados nas estações pluviométricas;  $i$  = representação de cada tempo de retorno (2, 5, 10, 15, 20 e 25 anos);  $n$  = número de diferentes tempos de retorno considerados ( $n=6$ ); A comparação foi conduzida separadamente para cada estação e considerando todos os TR. Fonte: Autor.

De acordo com Silva et al. (2020), o PBIAS mede a precisão de um modelo comparando a média dos dados estimados por satélite com a média dos dados observados. Ele avalia o grau em que o modelo tende a superestimar ou subestimar os valores reais. Um valor ideal de PBIAS é zero, indicando alinhamento entre os dados estimados e observados. Valores positivos sugerem que o modelo tende a superestimar, enquanto valores negativos indicam subestimação.

O RMSE avalia a magnitude média dos erros entre os dados do CHIRPS e os dados medidos em campo (Bayissa et al., 2017; J. Costa et al., 2019). Por outro lado, o MAE é uma análise estatística menos influenciada por valores atípicos. Essa métrica representa a soma acumulada dos erros e fornece uma estimativa robusta para indicar a capacidade dos dados estimados de replicar os valores observados (J. Costa et al.,

2019). Por fim, o NSE, que varia de  $-\infty$  a 1, auxilia na avaliação de uma possível subestimação geral da amostra e na análise da adequação entre as séries de dados.

Visando a obtenção de parâmetros para interpretação dos resultados obtidos, considerou-se também as classificações recomendadas por Rauf e Ghumman (2018), e Anjinho et al. (2021) para os indicadores PBIAS e NSE, apresentadas na Tabela 5, onde o PBIAS é classificado em quatro classes e o NSE é classificado em cinco classes.

**Tabela 5 - Classificação dos indicadores estatísticos de desempenho PBIAS e NSE**

Classes	PBIAS	NSE
Muito bom	< 5	0,75 - 1,00
Bom	5 - 10	0,65 - 0,75
Satisfatório	10 - 15	0,50 - 0,65
Aceitável	-	0,40 - 0,50
Insatisfatório	$\geq 15$	$\leq 0,40$

Fonte: Adaptado de Rauf e Ghumman (2018); Anjinho et al. (2021)

#### 4.6. Correção de viés dos dados de satélite

Estudos anteriores indicam que os produtos de precipitação por satélite apresentam erros aleatórios e também sistemáticos, especialmente na detecção de valores extremos de precipitação (Ombadi et al., 2018; Prakash et al., 2016; Sadeghi et al., 2021). Sendo assim, o viés dos valores extremos de precipitação precisa ser corrigido antes da sua aplicação no desenvolvimento das curvas IDF. Neste trabalho, o método da série de Precipitação Máxima Diária Anual (PMDA) foi utilizado para definir os valores extremos de precipitação, como propôs o estudo de Venkatesh (2022), adotado também por Mianabadi (2023). Para isso, as séries de PMDA foram extraídas tanto dos dados de campo quanto dos dados de satélite. A extensão temporal das séries é de 41 anos, de 1982 a 2022. Em seguida, as séries diárias de PMDA foram ordenadas do maior valor para o menor. O fator de correção de viés ( $f_{cv}$ ), como proposto por Mianabadi (2023), é definido pela razão entre a PMDA observada na estação  $j$  ( $PMDA_{Obs(i,j)}$ ) e a PMDA estimada por satélite  $j$  ( $PMDA_{Est(i,j)}$ ), conforme a Equação 2.

$$f_{cv} = \frac{PMDA_{Obs(i,j)}}{PMDA_{Est(i,j)}}$$

**Equação 2**

Nesta equação,  $i$  indica uma dada estação. Após o cálculo do fator de correção para cada evento, o fator médio é multiplicado pela série de PMDA original, obtendo assim a série de PMDA corrigida.

#### 4.6.1. Proposta de correção de viés para áreas não monitoradas

Após a determinação do  $f_{cv}$  para todas as estações, buscou-se verificar a relação deste fator com alguns parâmetros físicos e climáticos das estações utilizadas, como: localização geográfica (latitude, longitude), elevação, precipitação máxima diária anual média (PMDA) e precipitação total anual média (PRCPTOT). Essa relação foi verificada a partir do coeficiente de determinação ( $R^2$ ). Ombadi et al. (2018) observaram uma relação entre o fator de correção de viés e a elevação, indicada pelo valor do coeficiente de correlação de Pearson de 0,54. Segundo os autores, essa relação indica que, de maneira geral, o produto de satélite estudado tende a apresentar maior erro, particularmente de subestimação, em regiões mais elevadas. Isso se deve ao fato de que a estimativa de chuvas orográficas quentes sobre regiões de altitudes elevadas é desafiadora para algoritmos baseados em imagens infravermelho utilizados nos produtos de satélite (Dinku et al., 2008).

Após verificação dessas relações, a partir de uma regressão linear múltipla, foi possível determinar uma equação para calcular o  $f_{cv}$  apenas com base nas variáveis latitude e longitude. Deste modo, é possível fornecer um método de simples aplicação para efetuar a correção de viés dos dados estimados pelo CHIRPS em áreas não-monitoradas da Mesorregião Sul Baiano.

A partir das relações obtidas, foram testados modelos de regressão linear simples com cada uma das variáveis individualmente, bem como dois modelos de regressão linear múltipla com as variáveis que apresentaram relação mais forte com o  $f_{cv}$  calculado. Assim, ao todo foram testados cinco modelos de regressão linear: Reg1, Reg2, Reg3, Reg4 e Reg5. O coeficiente de determinação ( $R^2$ ) e o Erro Padrão (E) foram utilizados para avaliar os modelos. O E pode ser definido conforme a Equação 3.

$$E = \sqrt{\frac{\sum(y_i - \hat{y}_i)^2}{n - p}}$$

Equação 3

Nesta equação,  $y_i$  indica o valor observado da variável dependente.  $\hat{y}_i$  é o valor previsto da variável dependente estimado pela equação de regressão.  $n$  é o número de observações na amostra, e  $n - p$  indica os graus de liberdade para a regressão, onde  $p$  é o número de parâmetros estimados (por exemplo, para uma regressão linear simples, existem dois parâmetros: intersecção e inclinação, então  $p = 2$ ).

O software Plúvio 2.1 se tornou uma alternativa bastante utilizada para obtenção de equações IDF em áreas onde não há monitoramento de chuva no Brasil. No entanto, para o dimensionamento seguro de estruturas hidráulicas, é importante a utilização de equações IDF atualizadas, e as equações disponíveis no software podem estar defasadas, uma vez que as séries temporais utilizadas para definição das equações de referência no estado da Bahia possuem dados até o ano de 1999 (Silva et al., 2002). Assim, como o presente estudo propõe um outro método alternativo para obtenção de curvas IDF em áreas não monitoradas, os resultados obtidos pelas IDFs desenvolvidas a partir dos dados do CHIRPS corrigidos pelo método proposto foram comparados aos resultados obtidos por IDFs fornecidas pelo Plúvio, de modo a verificar a sua performance em relação ao que tem sido praticado atualmente. Vale ressaltar que, cinco estações utilizadas por Silva et al. (2002) foram utilizadas também no presente estudo, sendo elas: Itamaraju (1739005), Itapebi (1539006), Ituberá (1339012), Medeiros Neto (1740005) e Santa Cruz da Vitória (1439004).

#### **4.7. Análise de frequência sob a ótica da não estacionariedade**

##### **4.7.1. Identificação de tendência nas séries temporais**

Nesta etapa foram analisadas as séries temporais de precipitação máxima diária anual (PMDA) das estações que foram descartadas das análises anteriores devido à identificação de tendências nos testes realizados pelo algoritmo do GAM-IDF. O objetivo foi realizar uma análise estatística detalhada de modo a verificar a necessidade de análise de frequência a partir de métodos que consideram a hipótese de não estacionariedade das séries históricas. Nesta etapa, foi acrescentado nas séries temporais de PMDA o dado referente ao ano de 2023 e, portanto, o período de análise passou a ser de 1982 a 2023 (42 anos).

Inicialmente, foi feita uma análise exploratória dos dados através de gráficos e medidas descritivas. Em seguida, foi aplicado o teste de Shapiro-Wilk para avaliar se os dados de chuvas máxima diária são normalmente distribuídos. Foi aplicado

também o Box-test para verificar a independência entre os dados da série, sendo uma condição para aplicação do teste de Mann-Kendall.

Para a identificação de tendências nas séries históricas foi utilizado o teste não paramétrico de Mann-Kendall (Mann, 1945; Kendall, 1975), o qual é aplicado apenas a séries independentes. A hipótese nula do teste ( $H_0$ ) presume que os dados da série são isentos de tendência, enquanto a hipótese alternativa ( $H_1$ ) supõe que os dados da série apresentam tendência monotônica no tempo (Queiroz, 2013). Segundo Moraes et al. (1997), os  $n$  valores das séries temporais ( $x_1, x_2, x_3, \dots, x_n$ ) são ordenados de forma crescente ( $R_1, R_2, R_3, \dots, R_n$ ), sendo a estatística do teste  $S$  obtida pela Equação 4.

$$S = \sum_{i=1}^{n-1} \left( \sum_{j=i+1}^n \text{sgn}(R_i - R_j) \right) \quad \text{Equação 4}$$

Onde:

$\text{sgn}(x) = 1$  para  $x > 0$ ;

$\text{sgn}(x) = 0$  para  $x = 0$ ;

$\text{sgn}(x) = -1$  para  $x < 0$ .

Se a hipótese nula ( $H_0$ ) é confirmada, então  $S$  se aproxima de uma distribuição normal com:

$$\bar{X} = 0 \text{ e} \quad \text{Equação 5}$$

$$S = \frac{n(n-1)(2n+5)}{18} \quad \text{Equação 6}$$

A estatística  $Z$  é:

$$Z = \frac{|S|}{\sqrt{\sigma}} \quad \text{Equação 7}$$

Um valor positivo de  $S$  indica que existe uma tendência crescente e um valor negativo, decrescente.

Dentro do contexto dos testes não paramétricos empregados neste estudo, para verificar a existência de qualquer alteração abrupta, estatisticamente significativa, nas tendências, foi aplicado o teste de soma acumulada (CUSUM), acompanhado do teste

de Soma dos Ranks (rank-sum) para detectar alteração na mediana entre dois períodos da série divididos a partir do ano de mudança abrupta.

De acordo com Chiew e Siriwardena (2005), o teste de soma acumulada, ou CUSUM, examina se as medianas em duas partes de um conjunto de dados diferem (para um ponto de mudança de tempo desconhecido). Considerando uma sequência de dados  $(x_1, x_2, x_3, \dots, x_n)$ , a estatística do teste é definida como:

$$V_k = \sum_{i=1}^k \text{sgn}(x_i - x_{med}), \text{ com } k = 0, 1, 2, 3, \dots, n \quad \text{Equação 8}$$

onde,

$\text{sgn}(x) = 1$  para  $x > 0$ ,

$\text{sgn}(x) = 0$  para  $x = 0$ ,

$\text{sgn}(x) = -1$  para  $x < 0$ , e

$x_{med}$  = o valor mediano do conjunto de dados  $x_i$ .

A distribuição de  $V_k$  segue o teste de Kolmogorov-Smirnov, com estatística dada por:

$$KS = \frac{2}{N} \text{máx}|V_k| \quad \text{Equação 9}$$

Os valores críticos de  $\text{máx}|V_k|$  são dados por:

$\alpha = 0,10 \rightarrow 1,22 \sqrt{n}$ ,

$\alpha = 0,05 \rightarrow 1,36 \sqrt{n}$ ,

$\alpha = 0,01 \rightarrow 1,63 \sqrt{n}$ .

Um valor negativo de  $V_k$  indica que a parte mais recente do registro de dados tem mediana maior que a parte mais antiga.

No caso do teste *Rank-Sum* (não paramétrico), que também investiga se as medianas em dois períodos são distintas, os dados devem ser arranjados em ordem crescente, atribuindo a eles números de 1 a N, onde N representa o tamanho da amostra. A série é então dividida em dois grupos (para um tempo de mudança conhecido). Em situações em que há valores idênticos, a média das ordens de classificação é aplicada.

Conforme Chiew e Siriwardena (2005), a estatística S é computada como a soma dos ranks de observações do menor grupo (o número de observações no menor grupo é denotado como n e o número de observações no maior grupo é denotado por m).

Em seguida, a média e o desvio padrão de S são calculados a partir das seguintes equações:

$$\bar{X} = n \frac{(N + 1)}{2} \quad \text{Equação 10}$$

$$s = \left[ \frac{n m (N + 1)}{12} \right]^{0,5} \quad \text{Equação 11}$$

A estatística de teste  $Z_{rs}$  é computada a partir das seguintes condições:

$$Z_{rs} = (S - 0,5 - \bar{X})/s, \text{ se } S > \bar{X},$$

$$Z_{rs} = 0, \text{ se } S = \bar{X},$$

$$Z_{rs} = |S + 0,5 - \bar{X}|/s, \text{ se } S < \bar{X}.$$

$Z_{rs}$  é, aproximadamente, normalmente distribuído e os valores críticos da estatística de teste para vários níveis de significância podem ser obtidos a partir de tabelas de distribuição normal.

#### 4.7.2. Análise de frequência sob hipótese de não estacionariedade

Para a modelagem probabilística dos dados, foram testadas as distribuições GEV e Gumbel. A função de distribuição cumulativa da GEV é apresentada pela Equação 12.

$$G(x; \mu, \sigma, \xi) = \begin{cases} \exp \left\{ - \left( 1 + \xi \frac{x - \mu}{\sigma} \right)^{\frac{-1}{\xi}} \right\} \text{ se } \xi \neq 0, \text{ para } 1 + \xi \frac{x - \mu}{\sigma} > 0, \\ \exp \left\{ - \exp \left( - \frac{x - \mu}{\sigma} \right) \right\} \text{ se } \xi = 0 \end{cases} \quad \text{Equação 12}$$

onde  $\mu$ ,  $\sigma$ , e  $\xi$  representam os parâmetros de posição, escala e forma, respectivamente, e x, a precipitação máxima anual.

Enquanto a função de distribuição cumulativa de Gumbel é dada pela Equação 13.

$$F(X) = e^{-e^{-\frac{x-\mu}{\sigma}}} \quad \text{Equação 13}$$

onde  $\mu$  e  $\sigma$  representam os parâmetros de posição e escala, respectivamente, e  $x$ , a precipitação máxima anual.

Em casos não estacionários, os parâmetros das distribuições variam com o tempo (anos). Assim, o parâmetro de posição foi considerado como uma função  $\mu(t)$ , enquanto os parâmetros de escala e forma (apenas GEV) foram mantidos constantes. Foram consideradas três possibilidades de modelos para  $\mu(t)$ : o modelo estacionário [ $\mu(t) = \mu_0$ ]; uma tendência linear monotônica (Blanchet et al., 2018; Katz et al., 2002), apresentado na Equação 14; e uma tendência linear iniciando no ano  $t_0$  (Blanchet et al., 2018), representada na Equação 15. Nesses casos, o parâmetro  $\mu_1$  pode ser interpretado como a inclinação de uma tendência linear anual da variável.

Tendência linear monotônica:

$$\mu(t) = \mu_0 + \mu_1 t \quad \text{Equação 14}$$

Tendência linear iniciando no ano  $t_0$ :

$$\mu(t) = \begin{cases} \mu_0, & t \leq t_0 \\ \mu_0 + \mu_1(t - t_0), & t \geq t_0 \end{cases} \quad \text{Equação 15}$$

Os modelos foram ajustados pela máxima verossimilhança, a qual, segundo Coles (2001), é um dos métodos mais utilizados para determinação dos parâmetros de um modelo GEV não estacionário, tendo como vantagem a sua adaptabilidade para mudanças na estrutura do modelo.

A escolha do melhor modelo foi feita através dos critérios AIC e BIC, e através do teste de razão de verossimilhança (LTR). A análise estatística foi realizada através do RStudio versão 2024.04.02, com o uso dos pacotes: trend, forecast, dplyr e extRemes. Para todos os testes, considerou-se um nível de significância de 5%.

Segundo Moura (2021), o Critério de Informação de Akaike (AIC) avalia a qualidade do ajuste do modelo paramétrico, estimado pelo método da máxima verossimilhança e é definido conforme a Equação 16.

$$AIC = -2 \sum_{i=1}^n \log f(x_i | \hat{\theta}) + 2k = -2 \log L(\hat{\theta}) + 2k \quad \text{Equação 16}$$

onde  $L(\hat{\theta})$  é a função de verossimilhança maximizada e  $k$  é o número de parâmetros livres no modelo. O termo  $2k$  é o termo de penalidade e atua como uma compensação pelo viés na falta de ajuste quando os estimadores de máxima verossimilhança são usados.

O Critério de Informação Bayesiano (BIC) é baseado na avaliação de modelos definidos em termos de probabilidade a posteriori. Assim, seja  $F(x_n|\hat{\theta}_i)$  um modelo estatístico estimado através do método de máxima verossimilhança, então o critério BIC é definido pela Equação 17 (Moura, 2021).

$$BIC = -2 \sum_{i=1}^n \log f(x_i|\hat{\theta}) + k \log n = -2 \log L(\hat{\theta}) + k \log n \quad \text{Equação 17}$$

onde  $k$  é o número de parâmetros a serem escolhidos e  $n$  é o número de observações da amostra.

O AIC e o BIC são calculados para todos os modelos candidatos considerados em um processo de ajuste, e o modelo que apresentar o menor valor pode ser selecionado (Burnham e Anderson, 2002). Por outro lado, o teste de razão de verossimilhança ou *likelihood-ratio test* (LRT) pode ser aplicado apenas a pares de modelos aninhados que apresentem números diferentes de parâmetros (Kim et al., 2017). O LRT é um teste de hipóteses, cuja hipótese nula assume que não há diferença entre dois modelos aninhados. Sob essa hipótese, o LRT segue uma distribuição qui-quadrado com graus de liberdade iguais à diferença entre o número de parâmetros de cada modelo. O LRT (Equação 18) foi aplicado ao nível de significância de 5%. Assim, valores de LRT maiores que o quantil de 95% da distribuição qui-quadrado levaram à conclusão de que o modelo  $M_j$  é melhor que o modelo  $M_i$  (Xavier et al., 2019).

$$LRT = \{\log(ML_j) - \log(ML_i)\} \text{ para } M_i \subset M_j \quad \text{Equação 18}$$

onde  $\log(ML)$  é a função de log-verossimilhança maximizada.

## 5. RESULTADOS E DISCUSSÃO

### 5.1. Validação dos dados de sensoriamento remoto

#### 5.1.1. Desempenho das curvas IDF estimadas pelo CHIRPS

A partir das séries de precipitação extraídas das estações selecionadas, foram estimados os parâmetros das equações IDF, conforme o modelo da Equação 1, a partir dos dados observados (ANA) e dos dados estimados (CHIRPS). A Tabela 6 apresenta os resultados do processamento dos dados observados em campo. Das 31 estações testadas, 10 séries apresentaram tendência quando foi escolhida a primeira opção de importação dos dados (arquivo .csv do Hidroweb). Essa opção considera a série histórica completa das estações e algumas delas apresentam dados de períodos mais antigos, operando desde a década de 1940. Como o período de interesse é somente a partir de 1982, foi testada também a segunda opção de importação dos dados (série de PMDA de 1982 a 2022) e, para isso, foi replicado manualmente o processamento realizado pelo GAM-IDF, considerando os mesmos critérios de análise de consistência dos dados e anos falhos. Para esta opção, apenas 4 séries continuaram apresentando tendência e, portanto, as estações 1539022, 1739006, 1740026 e 1339020 foram descartadas da análise nesta etapa do trabalho. Vale ressaltar que esse resultado não implica necessariamente na ausência de tendência na série histórica de chuva diária uma vez que séries de máximos anuais, por natureza, não costumam apresentar tendência.

A FDP que melhor se ajustou aos dados de cada estação variou bastante, sendo utilizadas ao todo 7 das 12 funções testadas na modelagem do GAM-IDF. As FDPs mais comuns foram Logística Generalizada (7), Kappa (6), GEV (6) e Weibull (5).

A Tabela 7 apresenta os resultados do processamento dos dados estimados pelo CHIRPS. Neste caso, a segunda opção de importação dos dados foi a única possível uma vez que a primeira opção é programada exclusivamente para o arquivo padrão do Hidroweb. Neste caso, apenas uma série de PMDA apresentou tendência e, portanto, a estação 1439001 também foi descartada dessa análise. Este resultado reforça o argumento trazido anteriormente de que séries de PMDA não costumam apresentar tendência.

Neste caso, a FDP que melhor se ajustou aos dados de cada estação variou ainda mais, sendo utilizadas ao todo 8 das 12 funções testadas na modelagem do GAM-IDF. No entanto, as funções Kappa (11) e Logística Generalizada (9) foram muito mais recorrentes que as outras.

**Tabela 6 - Resultado do processamento das curvas IDF a partir dos dados observados no GAM-IDF**

N	Código	Mann-Kendall (.csv)	Mann-Kendall (PMDA 1982-2022)	FDP (melhor ajuste)	Parâmetros da IDF			
					a	b	c	d
1	1439001	Não há tendência	Não há tendência	Gumbel	650,743	0,216	9,242	0,708
2	1439023	Não há tendência	Não há tendência	Weibull	706,456	0,171	9,213	0,706
3	1439044	Não há tendência	Não há tendência	Lognormal 3P	593,281	0,190	9,225	0,707
4	1439089	Não há tendência	Não há tendência	Logística Generalizada	541,802	0,210	9,198	0,706
5	1539002	Não há tendência	Não há tendência	Kappa	625,799	0,175	9,234	0,707
6	1539006	Não há tendência	Não há tendência	GEV	659,080	0,162	9,222	0,707
7	1539010	tendência	Não há tendência	Logística Generalizada	454,628	0,281	9,254	0,708
8	1539014	tendência	Não há tendência	Weibull	645,727	0,137	9,223	0,707
9	1539022	tendência	tendência					
10	1639000	Não há tendência	Não há tendência	GEV	697,244	0,185	9,219	0,707
11	1739001	Não há tendência	Não há tendência	Kappa	828,339	0,190	9,211	0,707
12	1739005	Não há tendência	Não há tendência	Weibull	743,563	0,140	9,214	0,707
13	1739006	tendência	tendência					
14	1739010	tendência	Não há tendência	Logística Generalizada	945,646	0,117	9,213	0,706
15	1740001	Não há tendência	Não há tendência	Weibull	747,954	0,161	9,204	0,706
16	1740005	Não há tendência	Não há tendência	Logística Generalizada	655,514	0,172	9,233	0,707
17	1740006	Não há tendência	Não há tendência	GEV	671,273	0,163	9,202	0,706
18	1740008	Não há tendência	Não há tendência	Kappa	664,928	0,179	9,271	0,708
19	1740026	tendência	tendência					
20	1839000	Não há tendência	Não há tendência	Logística Generalizada	685,445	0,233	9,233	0,707
21	1840012	Não há tendência	Não há tendência	Weibull	862,396	0,163	9,222	0,707
22	1539016	Não há tendência	Não há tendência	Pearson Tipo III	625,283	0,200	9,210	0,706
23	1439002	Não há tendência	Não há tendência	Kappa	460,759	0,195	9,223	0,707
24	1539008	Não há tendência	Não há tendência	GEV	543,793	0,254	9,180	0,705
25	1339000	Não há tendência	Não há tendência	Kappa	601,937	0,185	9,238	0,707
26	1339012	Não há tendência	Não há tendência	Logística Generalizada	684,872	0,243	9,216	0,706
27	1339020	tendência	tendência					
28	1339027	tendência	Não há tendência	GEV	601,453	0,182	9,208	0,707
29	1339038	tendência	Não há tendência	Kappa	806,142	0,193	9,218	0,707
30	1339044	tendência	Não há tendência	Logística Generalizada	499,063	0,337	9,227	0,707
31	1439006	Não há tendência	Não há tendência	GEV	503,102	0,263	9,220	0,707

Fonte: Autor.

Vale ressaltar que, embora a distribuição de Gumbel seja amplamente utilizada em estudos de eventos extremos, ela foi selecionada em apenas duas estações. No entanto, o fato de uma determinada distribuição não ter sido selecionada não implica que ela não se ajustou à série de dados, mas sim que outra distribuição apresentou um ajuste melhor. Nota-se ainda que, na maioria dos casos, a FDP escolhida para os dados observados não foi mesma escolhida para os dados estimados da estação

correspondente. Apenas em 5 das 26 estações a FDP escolhida se repetiu. Essa diferença pode estar relacionada com a baixa correlação geralmente observada entre os dados de campo e os dados do CHIRPS na escala diária, como observado em estudos anteriores. Apesar desta diferença, cada equação foi modelada utilizando a FDP que forneceu melhor ajuste, visando minimizar os erros, não havendo necessidade de compatibilizar a FDP da estação correspondente.

**Tabela 7 - Resultado do processamento das curvas IDF a partir de dados do CHIRPS no GAM-IDF**

N	Código	Mann-Kendall (PMDA 1982-2022)	FDP (melhor ajuste)	Parâmetros da IDF			
				a	b	c	d
1	1439001	tendência					
2	1439023	não há tendência	Logística Generalizada	961,275	0,158	9,227	0,707
3	1439044	não há tendência	Kappa	593,739	0,137	9,222	0,707
4	1439089	não há tendência	Kappa	656,979	0,218	9,202	0,706
5	1539002	não há tendência	Normal Generalizada	1010,398	0,170	9,238	0,707
6	1539006	não há tendência	Weibull	693,023	0,198	9,220	0,707
7	1539010	não há tendência	Logística Generalizada	916,208	0,176	9,222	0,707
8	1539014	não há tendência	Weibull	782,373	0,129	9,209	0,706
9	1539022	não há tendência	Logística Generalizada	965,848	0,125	9,215	0,707
10	1639000	não há tendência	Pareto Generalizada	746,730	0,153	9,197	0,706
11	1739001	não há tendência	GEV	982,388	0,222	9,226	0,707
12	1739005	não há tendência	Logística Generalizada	765,014	0,187	9,228	0,707
13	1739006	não há tendência	Kappa	709,419	0,248	9,208	0,706
14	1739010	não há tendência	GEV	991,134	0,118	9,220	0,707
15	1740001	não há tendência	Logística Generalizada	531,229	0,223	9,243	0,707
16	1740005	não há tendência	Kappa	618,831	0,143	9,165	0,706
17	1740006	não há tendência	Pearson Tipo III	699,188	0,145	10,432	0,738
18	1740008	não há tendência	Kappa	558,822	0,119	9,221	0,707
19	1740026	não há tendência	Logística Generalizada	483,090	0,161	9,197	0,706
20	1839000	não há tendência	Kappa	593,862	0,295	9,425	0,712
21	1840012	não há tendência	Logística Generalizada	692,275	0,251	11,060	0,767
22	1539016	não há tendência	Kappa	602,672	0,115	9,236	0,707
23	1439002	não há tendência	Kappa	648,766	0,213	9,218	0,706
24	1539008	não há tendência	Kappa	498,227	0,191	9,461	0,714
25	1339000	não há tendência	Kappa	892,544	0,183	9,226	0,707
26	1339012	não há tendência	Kappa	1168,103	0,212	9,217	0,707
27	1339020	não há tendência	Logística Generalizada	1593,973	0,223	9,228	0,707
28	1339027	não há tendência	Logística Generalizada	1045,298	0,171	9,223	0,707
29	1339038	não há tendência	Pearson Tipo III	1586,110	0,198	9,254	0,707
30	1339044	não há tendência	Gumbel	1484,040	0,207	9,222	0,707
31	1439006	não há tendência	Normal Generalizada	813,701	0,148	9,212	0,706

Fonte: Autor.

A partir dos parâmetros estimados para cada IDF, conforme Tabela 6 e Tabela 7, foram calculadas as intensidades para uma chuva de 10 minutos de duração para diferentes Tempos de Retorno (2 a 25 anos), apresentadas na Tabela 8.

**Tabela 8 – Intensidades (mm/h) calculadas para uma chuva de 10 min de duração**

N	Código	TR = 2 anos		TR = 5 anos		TR = 10 anos		TR = 15 anos		TR = 20 anos		TR = 25 anos	
		Obs.	Est.	Obs.	Est.	Obs.	Est.	Obs.	Est.	Obs.	Est.	Obs.	Est.
1	1439023	98,71	132,64	115,45	153,31	129,98	171,05	139,31	182,37	146,33	190,85	152,02	197,70
2	1439044	83,71	80,76	99,63	91,56	113,65	100,68	122,75	106,43	129,65	110,71	135,26	114,15
3	1439089	77,82	94,87	94,33	115,85	109,11	134,74	118,81	147,20	126,21	156,72	132,26	164,54
4	1539002	87,35	140,53	102,55	164,22	115,77	184,75	124,28	197,94	130,70	207,86	135,91	215,89
5	1539006	91,21	98,34	105,81	117,90	118,38	135,25	126,42	146,55	132,45	155,15	137,33	162,15
6	1539010	68,05	128,04	88,03	150,44	106,96	169,96	119,87	182,53	129,96	192,01	138,37	199,70
7	1539014	87,83	106,19	99,57	119,52	109,49	130,70	115,75	137,71	120,40	142,92	124,14	147,09
8	1639000	98,06	103,10	116,17	118,62	132,06	131,89	142,35	140,33	150,13	146,64	156,46	151,73
9	1739001	116,93	141,71	139,17	173,68	158,76	202,57	171,47	221,65	181,11	236,27	188,95	248,27
10	1739005	101,38	107,70	115,25	127,83	127,00	145,52	134,42	156,98	139,94	165,66	144,38	172,72
11	1739010	127,27	133,06	141,67	148,25	153,64	160,89	161,11	168,77	166,62	174,60	171,03	179,26
12	1740001	103,82	76,64	120,32	94,01	134,52	109,72	143,60	120,11	150,41	128,07	155,91	134,60
13	1740005	91,31	84,95	106,90	96,84	120,44	106,94	129,14	113,32	135,69	118,08	141,00	121,91
14	1740006	93,31	83,41	108,34	95,27	121,30	105,34	129,59	111,72	135,81	116,48	140,84	120,31
15	1740008	92,67	75,07	109,19	83,72	123,61	90,92	132,92	95,41	139,94	98,73	145,64	101,39
16	1839000	99,61	88,14	123,31	115,50	144,93	141,70	159,29	159,71	170,33	173,85	179,42	185,68
17	1840012	119,43	79,57	138,67	100,14	155,26	119,18	165,87	131,94	173,83	141,82	180,27	149,99
18	1539016	89,15	80,69	107,08	89,66	123,00	97,10	133,39	101,73	141,29	105,16	147,74	107,89
19	1439002	65,24	93,31	78,00	113,42	89,29	131,46	96,64	143,32	102,21	152,37	106,76	159,79
20	1539008	80,81	68,31	101,99	81,37	121,63	92,89	134,82	100,37	145,04	106,04	153,50	110,65
21	1339000	84,59	125,32	100,22	148,19	113,93	168,24	122,81	181,19	129,52	190,99	134,98	198,95
22	1339012	100,58	167,39	125,66	203,28	148,71	235,46	164,11	256,59	175,99	272,73	185,80	285,94
23	1339027	84,44	145,56	99,77	170,26	113,18	191,68	121,85	205,44	128,40	215,80	133,72	224,20
24	1339038	114,01	224,79	136,06	269,51	155,54	309,16	168,20	335,00	177,80	354,63	185,62	370,65
25	1339044	77,96	211,89	106,17	256,15	134,10	295,67	153,73	321,55	169,39	341,28	182,61	357,42
26	1439006	74,68	111,90	95,03	128,15	114,04	141,99	126,87	150,77	136,84	157,33	145,11	162,61

Onde: Obs. = dados observados em campo; Est. = dados estimados pelo CHIRPS. Fonte: Autor.

Com as intensidades obtidas na Tabela 8, foram calculados os valores dos indicadores estatísticos de desempenho (Quadro 6) do CHIRPS em relação aos dados de campo (referência), e os resultados estão apresentados na Tabela 9.

Os resultados do indicador PBIAS mostram que o viés foi positivo para algumas estações e negativo para outras, com valores chegando até 116,51%, na estação 1339044. Os indicadores RMSE e MAE apresentam erros médios de 43,56 mm/h e 42,74 mm/h, respectivamente, enquanto o NSE apresenta um valor médio de -2,78. Os resultados de PBIAS e NSE obtidos na Tabela 9 foram classificados de acordo com a Tabela 5 para auxiliar na interpretação dos resultados (Tabela 10).

**Tabela 9 - Indicadores estatísticos de desempenho do CHIRPS**

<b>N</b>	<b>Código</b>	<b>PBIAS</b>	<b>RMSE (mm/h)</b>	<b>MAE (mm/h)</b>	<b>NSE</b>
1	1439023	31,48%	41,22	41,02	-4,02
2	1439044	-11,74%	14,79	13,39	0,62
3	1439089	23,60%	26,43	25,90	0,10
4	1539002	59,53%	69,72	69,10	-9,08
5	1539006	14,58%	18,34	17,29	0,14
6	1539010	57,04%	61,92	61,91	-2,60
7	1539014	19,32%	21,22	21,16	0,23
8	1639000	-0,37%	3,42	2,98	0,97
9	1739001	28,00%	46,19	44,62	-0,46
10	1739005	14,96%	20,47	19,01	-0,82
11	1739010	4,72%	7,29	7,25	0,93
12	1740001	-17,99%	24,33	24,24	-0,73
13	1740005	-11,38%	14,43	13,74	0,46
14	1740006	-13,26%	16,52	16,11	0,21
15	1740008	-26,71%	34,38	33,12	-2,16
16	1839000	-1,40%	6,52	5,45	0,96
17	1840012	-22,57%	35,28	35,12	-0,15
18	1539016	-21,50%	28,70	26,57	-0,82
19	1439002	47,48%	43,45	42,59	-0,02
20	1539008	-24,15%	31,49	29,69	-0,45
21	1339000	47,64%	55,06	54,47	-4,45
22	1339012	57,78%	87,52	86,76	-5,08
23	1339027	69,21%	79,24	78,60	-10,03
24	1339038	98,86%	156,53	154,42	-18,12
25	1339044	116,51%	160,62	160,00	-17,99
26	1439006	23,13%	27,57	26,70	0,06
<b>Média</b>		<b>21,64%</b>	<b>43,56</b>	<b>42,74</b>	<b>-2,78</b>

Fonte: Autor.

**Tabela 10 - Classificação dos resultados de PBIAS e NSE**

<b>Classes</b>	<b>PBIAS</b>	<b>NSE</b>
Muito bom	3	3
Bom	0	0
Satisfatório	5	1
Aceitável	-	1
Insatisfatório	18	21

Fonte: Autor.

Considerando a classificação adotada para o indicador PBIAS, a maioria das estações (18) apresentaram resultado insatisfatório, 5 tiveram resultado satisfatório e 3 muito bom. No que diz respeito à classificação com base no NSE, 21 estações tiveram desempenho insatisfatório, enquanto 1 estação foi aceitável, 1 foi satisfatória e 3 muito boas.

Esses resultados revelam que, de modo geral, o CHIRPS, no seu estado original, não apresenta desempenho satisfatório para definição de curvas IDF na Mesorregião Sul Baiano. Esses resultados estão em consonância com estudos anteriores no que se refere aos erros apresentados por produtos de satélite na estimativa de valores extremos de precipitação (Ombadi et al., 2018; Prakash et al., 2016; Sadeghi et al., 2021). Sendo assim, verificou-se a necessidade de correção de viés dos valores estimados pelo CHIRPS antes da sua aplicação na determinação de curvas IDF.

Para correção do viés das séries de máximas anuais do CHIRPS, foi calculado o fator de correção de viés ( $f_{cv}$ ), apresentado na Tabela 11, juntamente com os demais parâmetros de cada estação utilizada. Observa-se que o  $f_{cv}$  variou de 0,360 a 1,388. Valores menores que 1 indicam que o CHIRPS superestimou as precipitações máximas neste ponto, enquanto valores maiores que 1 indicam que as chuvas foram subestimadas pelo produto.

A metodologia aplicada para correção de viés requer a utilização de séries de dados de precipitação medidos em campo, porém, devido à baixa densidade e má distribuição da rede de monitoramento hidrológico no Brasil, mais especificamente no Estado da Bahia, esses dados não estão disponíveis em muitas localidades. Em muitos lugares, ainda que haja postos pluviométricos, as séries históricas apresentam uma grande quantidade de falhas devido, principalmente, à falta de manutenção adequada. Assim, este estudo buscou relacionar os fatores de correção de viés calculados (Tabela 11) com parâmetros físicos e climáticos das estações utilizadas, a fim de propor um método para correção de viés que não depende da utilização de dados medidos em campo.

**Tabela 11 – Fator de correção de viés calculado para as estações**

<b>N</b>	<b>Código</b>	<b>Nome</b>	<b>Longitude</b>	<b>Latitude</b>	<b>PRCPTOT (média)</b>	<b>Elevação (m)</b>	<b>PMDA média (mm)</b>	<b><math>f_{cv}</math></b>
1	1439001	LOMANTO JUNIOR	-39,4714	-14,8103	1428,710	145	74,865	<b>0,712</b>
2	1439023	ITAJUÍPE (PIRANJI)	-39,3894	-14,6778	1482,463	106	79,405	<b>0,729</b>
3	1439044	SANTA CRUZ DA VITÓRIA	-39,8075	-14,9589	896,418	234	67,370	<b>0,998</b>
4	1439089	IBICARÁI	-39,5883	-14,8694	1089,457	164	65,213	<b>0,795</b>
5	1539002	SÃO JOSÉ	-39,3456	-15,0922	1421,389	165	74,726	<b>0,643</b>
6	1539006	ITAPEBI	-39,5261	-15,9608	1142,820	159	73,294	<b>0,903</b>
7	1539010	MASCOTE	-39,3017	-15,5642	1377,663	45	65,456	<b>0,580</b>
8	1539014	FAZENDA NANCY	-39,5169	-15,6033	1084,490	60	69,559	<b>0,792</b>
9	1539022	CAMACAN (VARGITO)	-39,4928	-15,4253	1479,825	151	75,392	<b>0,693</b>
10	1639000	MUNDO NOVO	-39,5833	-16,265	1095,407	138	79,951	<b>0,978</b>
11	1739001	PRADO	-39,22	-17,3503	1337,003	11	91,149	<b>0,723</b>
12	1739005	ITAMARAJU	-39,5447	-17,045	1260,523	19	80,823	<b>0,923</b>
13	1739006	HELVÉCIA (EFBM)	-39,6625	-17,8081	1257,049	64	82,643	<b>0,914</b>
14	1739010	ALCOBAÇA	-39,2275	-17,5156	1452,008	5	99,958	<b>0,898</b>
15	1740001	NANUQUE – MONTANTE	-40,3772	-17,8375	888,774	169	84,124	<b>1,235</b>
16	1740005	MEDEIROS NETO	-40,2258	-17,3722	959,113	146	76,632	<b>1,127</b>
17	1740006	SÃO JOSÉ DO PRADO	-39,9822	-17,1875	1156,720	104	77,290	<b>1,125</b>
18	1740008	ITANHÉM	-40,3267	-17,1633	1109,600	212	78,087	<b>1,284</b>
19	1740026	SÃO PEDRO DO PAMPÁ	-40,6761	-17,3203	992,286	191	82,811	<b>1,388</b>
20	1839000	MORRO D'ANTA (PEDRO CANÁRIO)	-39,9586	-18,2994	977,386	65	80,597	<b>0,974</b>
21	1840012	FAZENDA LIMOEIRO	-40,1439	-18,1456	1053,823	112	93,233	<b>1,273</b>
22	1539016	FAZENDA MANAUS	-39,7692	-15,1544	776,458	175	73,454	<b>1,093</b>
23	1439002	FLORESTA AZUL	-39,6583	-14,8597	998,218	196	56,258	<b>0,689</b>
24	1539008	ITAJÚ DO COLÔNIA	-39,7242	-15,1389	745,119	166	69,647	<b>1,108</b>
25	1339000	SANTA LUZIA	-39,4917	-13,6011	1497,266	175	68,671	<b>0,652</b>
26	1339012	ITUBERÁ	-39,1692	-13,8106	1778,891	54	89,397	<b>0,627</b>
27	1339020	ARATUIPE	-39,0019	-13,5669	1953,179	7	83,985	<b>0,450</b>
28	1339027	WENCESLAU GUIMARÃES	-39,4789	-13,6847	1180,757	148	66,608	<b>0,547</b>
29	1339038	VALENÇA	-39,0772	-13,3672	2016,426	4	94,277	<b>0,540</b>
30	1339044	NILO PEÇANHA	-39,1247	-13,5967	1533,650	60	67,508	<b>0,360</b>
31	1439006	PEDRINHAS	-39,4686	-14,3267	972,845	95	63,444	<b>0,652</b>

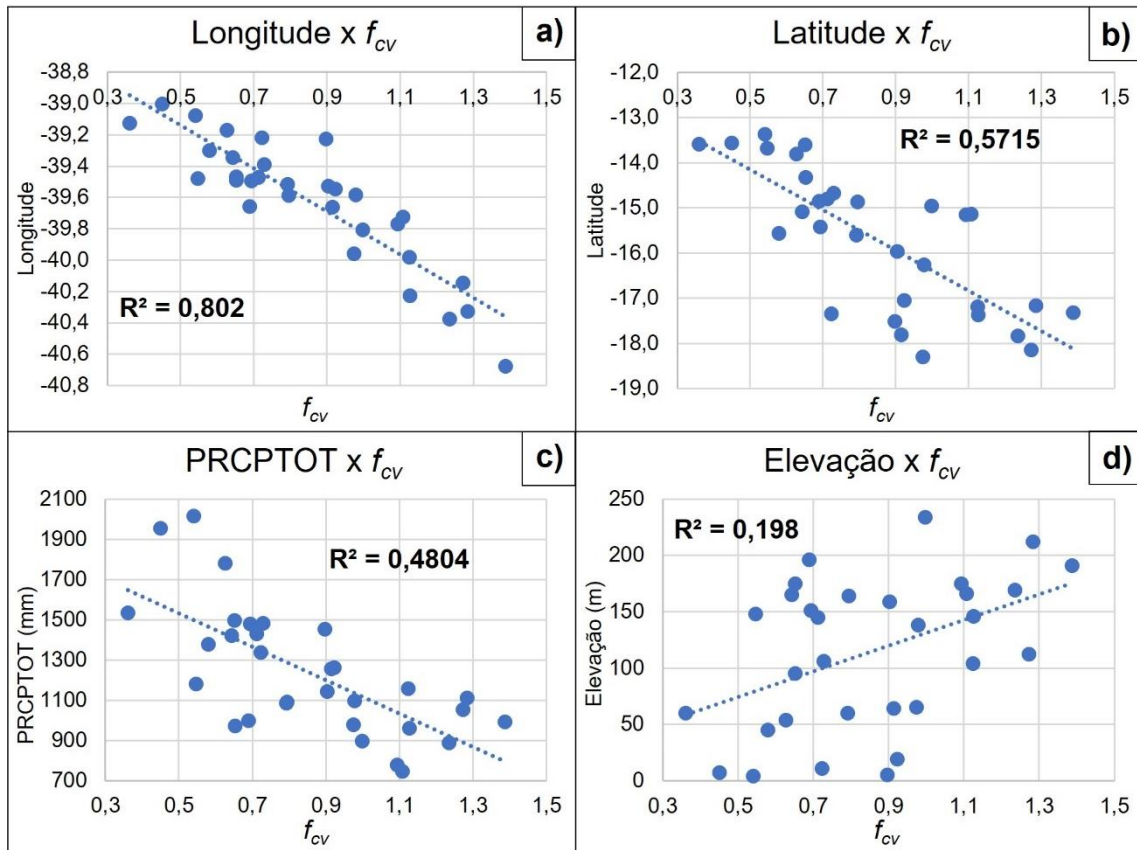
Fonte: Autor.

## 5.2. Proposta de correção de viés para utilização para áreas não monitoradas

A Figura 6 apresenta o cruzamento do  $f_{cv}$  com os demais fatores analisados em gráficos de dispersão, com suas respectivas linhas de tendência e  $R^2$ . A longitude apresentou relação mais forte, com  $R^2$  igual a 0,802, seguida da latitude ( $R^2 = 0,5715$ ), PRCPTOT ( $R^2 = 0,4804$ ), enquanto a elevação apresentou a relação mais fraca, com

$R^2$  igual a 0,198. O parâmetro PMDA apresentou uma relação muito baixa com o  $f_{cv}$  ( $R^2 = 0,057$ ) e, portanto, foi descartado das análises.

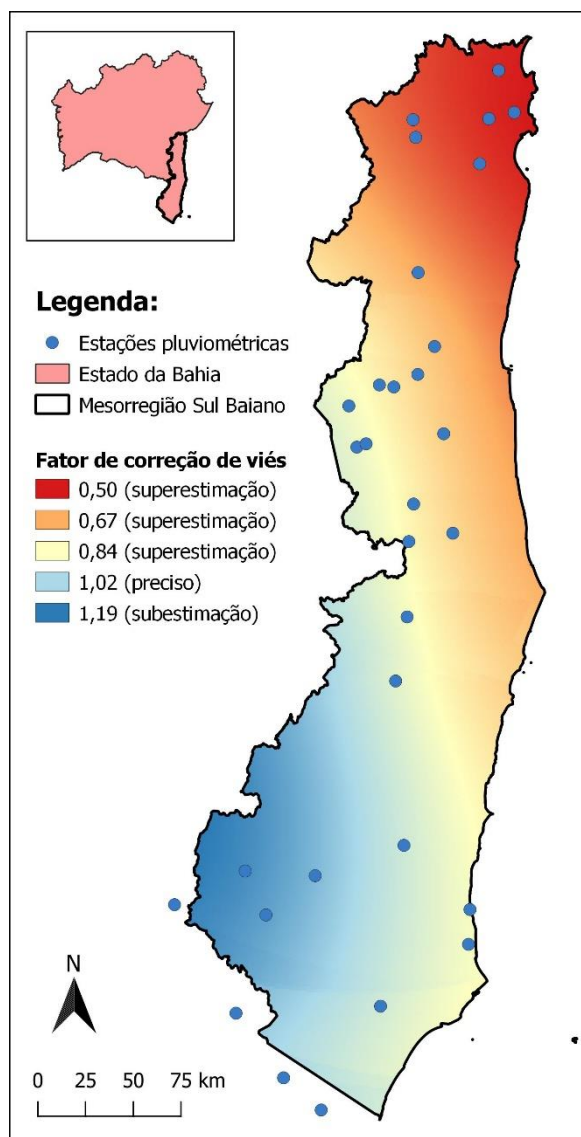
**Figura 6 – Relação entre o fator de correção de viés ( $f_{cv}$ ) e a longitude (a), latitude (b), PRCPTOT (c) e Elevação (d)**



Fonte: Autor.

Na Figura 7 é possível visualizar claramente a relação entre o  $f_{cv}$  e a localização geográfica das estações (latitude, longitude). Na área mais alaranjada, os valores de  $f_{cv}$  são menores que 1, ou seja, as estimativas do CHIRPS estão sendo corrigidas para baixo. Isso significa que, nessa área, o CHIRPS tende a superestimar as precipitações máximas. Por outro lado, à medida que se aproxima da área azul, os valores de  $f_{cv}$  são maiores que 1, isto é, as estimativas do CHIRPS são corrigidas para cima, indicando que as precipitações máximas são subestimadas pelo produto nessa área.

Figura 7 – Interpolação do  $f_{cv}$  ao longo da Mesorregião Sul Baiano



Fonte: Autor.

Considerando os resultados da Figura 6, a variável elevação também foi desconsiderada por apresentar relação mais fraca ( $R^2 = 0,198$ ). Assim, três modelos de regressão linear simples foram testados, envolvendo longitude (Reg1), latitude (Reg2) e PRCPTOT (Reg3), individualmente. Além disso, dois modelos de regressão linear múltipla foram testados: o primeiro envolvendo longitude e latitude (Reg4), e o segundo envolvendo longitude, latitude e PRCPTOT (Reg5), visto que foram as variáveis que apresentaram relação mais forte com o  $f_{cv}$  calculado. Assim, as informações de cada um dos cinco modelos e os respectivos indicadores estatísticos da regressão estão apresentados na Tabela 12.

**Tabela 12 - Modelos de regressão linear testados para correção de viés**

Nome	Variáveis	Tipo	R <sup>2</sup>	E
Reg1	Longitude	Simple	0,795	0,1255
Reg2	Latitude	Simple	0,557	0,1638
Reg3	PRCPTOT	Simple	0,462	0,1868
Reg4	Longitude e Latitude	Múltipla	0,926	0,1030
Reg5	Longitude, Latitude e PRCPTOT	Múltipla	0,928	0,1076

Fonte: Autor.

A Longitude é o fator que possui relação mais forte com o  $f_{cv}$ , porém, quando este fator é associado à Latitude e PRCPTOT, os resultados do modelo de regressão são melhores do que quando utilizado sozinho. Os modelos que apresentaram melhor desempenho foram os modelos de regressão múltipla Reg4 e Reg5, com R<sup>2</sup> igual a 0,926 e 0,928, respectivamente. No entanto, o Reg5 apresentou Erro Padrão (E) de 0,1076, ligeiramente maior que o E do Reg4, igual a 0,1030.

A Tabela 13 apresenta os indicadores estatísticos dos parâmetros estimados envolvidos em cada regressão. De modo geral, o Reg5 apresentou Erro Padrão maior que o Reg4 em todos os parâmetros. Além disso, ainda sobre o Reg5, a variável PRCPTOT não apresentou significância estatística, ao nível de 5%, para explicar a variável resposta ( $f_{cv}$ ) neste modelo, uma vez que o valor-P desta variável foi de 0,3252. Todos os outros modelos tiveram parâmetros com significância estatística, isto é, valor-P abaixo de 5%.

**Tabela 13 - Estatística dos coeficientes estimados para cada modelo de regressão**

Nome	Interseção		Longitude		Latitude		PRCPTOT	
	Erro padrão	valor-P	Erro padrão	valor-P	Erro padrão	valor-P	Erro padrão	valor-P
Reg1	2,129	2,483E-11	0,0537	1,033E-11				
Reg2	0,325	0,00127			0,0206	8,753E-07		
Reg3	0,143	7,481E-12					0,000112	1,547E-05
Reg4	2,255	1,140E-08	0,0608	3,863E-08	0,0158	0,00279		
Reg5	2,957	9,796E-06	0,0758	1,074E-05	0,0158	0,00320	8,491E-05	0,325

Fonte: Autor.

A Tabela 14 apresenta o resultado dos fatores de correção de viés calculados a partir dos modelos de regressão e seus respectivos erros em relação ao  $f_{cv}$  original.

**Tabela 14 - Resultado dos fatores de correção de viés calculados a partir dos modelos de regressão e seus respectivos erros em relação ao  $f_{cv}$  original**

N	Código	f <sub>cv</sub> original	Reg1		Reg2		Reg3		Reg4		Reg5	
			f <sub>cv</sub> (reg)	E	f <sub>cv</sub> (reg)	E	f <sub>cv</sub> (reg)	E	f <sub>cv</sub> (reg)	E	f <sub>cv</sub> (reg)	E
1	1439001	0,712	0,763	0,072	0,735	0,032	0,712	0,001	0,736	0,033	0,727	0,021
2	1439023	0,729	0,715	0,018	0,718	0,015	0,680	0,068	0,691	0,051	0,682	0,064
3	1439044	0,998	0,959	0,039	0,754	0,245	1,031	0,033	0,896	0,102	0,917	0,081
4	1439089	0,795	0,831	0,046	0,742	0,066	0,915	0,152	0,792	0,004	0,806	0,015
5	1539002	0,643	0,690	0,073	0,771	0,198	0,716	0,114	0,693	0,078	0,690	0,074
6	1539006	0,903	0,795	0,120	0,882	0,024	0,883	0,022	0,820	0,092	0,832	0,079
7	1539010	0,580	0,664	0,146	0,831	0,433	0,742	0,281	0,698	0,203	0,700	0,208
8	1539014	0,792	0,790	0,003	0,836	0,055	0,918	0,159	0,797	0,006	0,815	0,029
9	1539022	0,693	0,776	0,118	0,813	0,173	0,681	0,018	0,777	0,121	0,763	0,100
10	1639000	0,978	0,828	0,153	0,921	0,059	0,912	0,068	0,862	0,119	0,875	0,105
11	1739001	0,723	0,617	0,147	1,060	0,466	0,767	0,061	0,753	0,042	0,762	0,054
12	1739005	0,923	0,806	0,127	1,020	0,106	0,813	0,119	0,885	0,041	0,885	0,040
13	1739006	0,914	0,874	0,044	1,118	0,223	0,815	0,109	0,978	0,069	0,973	0,064
14	1739010	0,898	0,621	0,308	1,081	0,204	0,698	0,223	0,765	0,148	0,764	0,149
15	1740001	1,235	1,291	0,045	1,122	0,092	1,036	0,162	1,304	0,055	1,298	0,050
16	1740005	1,127	1,202	0,067	1,062	0,057	0,994	0,118	1,211	0,075	1,206	0,071
17	1740006	1,125	1,061	0,057	1,039	0,077	0,875	0,222	1,091	0,030	1,080	0,039
18	1740008	1,284	1,261	0,018	1,036	0,194	0,903	0,297	1,246	0,030	1,224	0,047
19	1740026	1,388	1,465	0,055	1,056	0,239	0,974	0,298	1,413	0,018	1,385	0,002
20	1839000	0,974	1,047	0,074	1,181	0,212	0,983	0,008	1,138	0,168	1,143	0,173
21	1840012	1,273	1,155	0,093	1,161	0,088	0,937	0,264	1,214	0,046	1,204	0,054
22	1539016	1,093	0,937	0,143	0,779	0,288	1,103	0,009	0,889	0,187	0,922	0,157
23	1439002	0,689	0,872	0,265	0,741	0,075	0,970	0,407	0,823	0,194	0,842	0,222
24	1539008	1,108	0,910	0,178	0,777	0,299	1,122	0,013	0,867	0,217	0,905	0,183
25	1339000	0,652	0,775	0,189	0,580	0,110	0,671	0,029	0,682	0,046	0,667	0,024
26	1339012	0,627	0,587	0,063	0,607	0,032	0,502	0,200	0,546	0,128	0,522	0,167
27	1339020	0,450	0,490	0,088	0,576	0,278	0,397	0,118	0,458	0,017	0,427	0,052
28	1339027	0,547	0,768	0,404	0,591	0,081	0,861	0,575	0,681	0,245	0,693	0,268
29	1339038	0,540	0,534	0,013	0,550	0,018	0,359	0,335	0,482	0,109	0,442	0,182
30	1339044	0,360	0,561	0,558	0,579	0,608	0,649	0,800	0,515	0,429	0,514	0,426
31	1439006	0,652	0,762	0,168	0,673	0,032	0,985	0,511	0,709	0,087	0,740	0,134
<b>Erro padrão médio</b>			<b>0,126</b>		<b>0,164</b>		<b>0,187</b>		<b>0,103</b>		<b>0,108</b>	

Fonte: Autor.

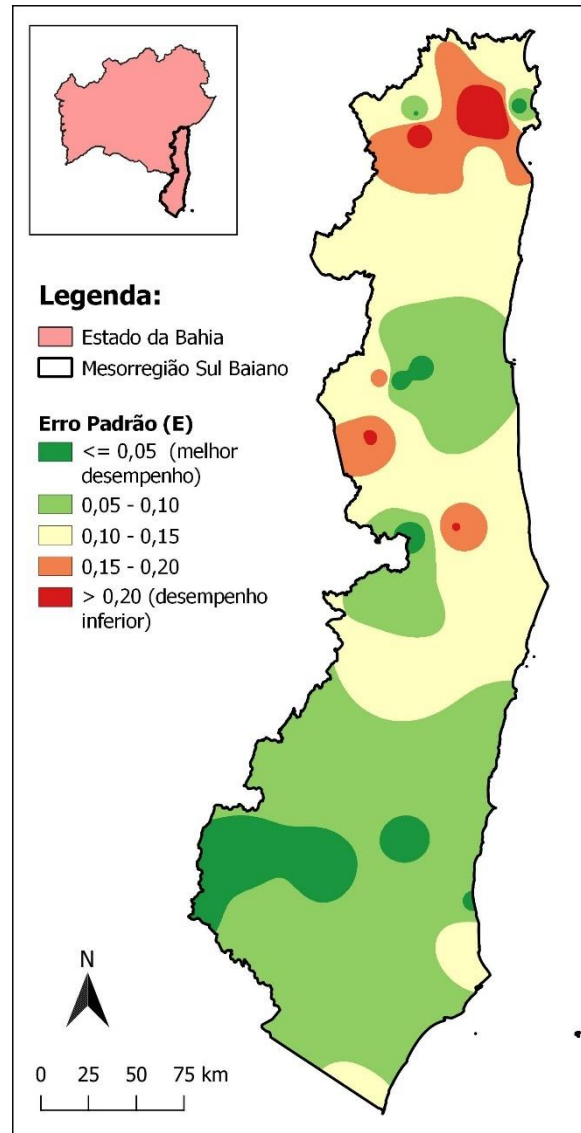
O modelo de regressão linear múltipla envolvendo longitude e latitude (Reg4) foi o que representou melhor a variável resposta ( $f_{cv}$ ), dando origem à Equação 19.

$$f_{cv(reg)} = -0,45404 \times long - 0,05185 \times lat - 17,954 \quad \text{Equação 19}$$

Foi calculado o intervalo de confiança com base no Erro Padrão encontrado para as estimativas do Reg4 (Tabela 14), e pode-se afirmar com 95% de confiança que, ao utilizar o Reg4 para determinar o fator de correção de viés na área de estudo, o erro associado estará entre -0,4% e 21% do valor esperado para o  $f_{cv}$ .

A Figura 8 apresenta a interpolação do Erro Padrão (E) para as estimativas do modelo escolhido (Reg4) ao longo da área de estudo. Esta figura permite visualizar as áreas onde o modelo teve melhor desempenho e, principalmente, as áreas onde os erros foram maiores e, conseqüentemente, a sua utilização pode não ser recomendada.

**Figura 8 – Interpolação do Erro Padrão (E) do  $f_{cv(reg)}$  em relação ao  $f_{cv}$  original**



Fonte: Autor.

O mesmo procedimento de avaliação do desempenho dos dados do CHIRPS, apresentado no item anterior, foi repetido após a aplicação do fator de correção de viés original ( $f_{cv}$ ) e do fator de correção de viés com base na regressão linear ( $f_{cv(reg)}$ ), a partir da Equação 19.

### 5.2.1. Desempenho das curvas IDF após a correção de viés

O mesmo procedimento foi realizado com os dados do CHIRPS após a aplicação do  $f_{cv}$  (Tabela 15) e após a aplicação do  $f_{cv(reg)}$  (Tabela 16). Observa-se na Tabela 15 que, das 26 estações analisadas, apenas 4 apresentaram piora nos indicadores estatísticos após a aplicação do  $f_{cv}$ , enquanto as outras 22 apresentaram melhora. Quanto ao PBIAS, o valor de 116,51%, referente à estação 1339044, caiu para -21,93% após a correção de viés. O RMSE médio caiu de 43,56 mm/h para 10,09 mm/h e o MAE médio caiu de 42,74 mm/h para 9,03 mm/h. O NSE médio também apresentou uma melhora significativa, subindo de -2,78 para 0,78.

Apesar da melhora geral dos indicadores, algumas estações ainda apresentam erros consideráveis mesmo após a correção de viés, a exemplo das estações 1439044, 1539016, 1539008, 1339044 e 143900, sendo todas com PBIAS negativo maior que 10%.

Tabela 15 - Indicadores estatísticos de desempenho após a aplicação do  $f_{cv}$

N	Código	PBIAS		RMSE (mm/h)		MAE (mm/h)		NSE	
		Estimado	Corrigido	Estimado	Corrigido	Estimado	Corrigido	Estimado	Corrigido
1	1439023	31,48%	-4,26%	41,22	5,91	41,02	5,54	-4,02	0,90
2	1439044	-11,74%	-11,91%	14,79	14,98	13,39	13,59	0,62	0,61
3	1439089	23,60%	-1,71%	26,43	1,91	25,90	1,88	0,10	1,00
4	1539002	59,53%	2,47%	69,72	2,87	69,10	2,87	-9,08	0,98
5	1539006	14,58%	3,46%	18,34	5,72	17,29	4,91	0,14	0,92
6	1539010	57,04%	-8,65%	61,92	13,67	61,91	11,54	-2,60	0,82
7	1539014	19,32%	-5,74%	21,22	6,46	21,16	6,29	0,23	0,93
8	1639000	-0,37%	-2,72%	3,42	5,22	2,98	4,47	0,97	0,93
9	1739001	28,00%	-7,81%	46,19	12,56	44,62	12,45	-0,46	0,89
10	1739005	14,96%	6,16%	20,47	9,80	19,01	8,47	-0,82	0,58
11	1739010	4,72%	-5,88%	7,29	9,06	7,25	9,03	0,93	0,89
12	1740001	-17,99%	1,26%	24,33	6,86	24,24	6,10	-0,73	0,86
13	1740005	-11,38%	0,16%	14,43	2,75	13,74	2,36	0,46	0,98
14	1740006	-13,26%	-2,60%	16,52	3,79	16,11	3,27	0,21	0,96
15	1740008	-26,71%	-5,70%	34,38	9,68	33,12	8,38	-2,16	0,75
16	1839000	-1,40%	-3,99%	6,52	7,95	5,45	6,34	0,96	0,94
17	1840012	-22,57%	-1,29%	35,28	9,91	35,12	8,46	-0,15	0,91
18	1539016	-21,50%	-14,08%	28,70	20,05	26,57	17,40	-0,82	0,11
19	1439002	47,48%	1,51%	43,45	2,00	42,59	1,70	-0,02	1,00
20	1539008	-24,15%	-15,62%	31,49	21,29	29,69	19,21	-0,45	0,34
21	1339000	47,64%	-3,84%	55,06	4,47	54,47	4,39	-4,45	0,96
22	1339012	57,78%	-0,81%	87,52	3,91	86,76	3,48	-5,08	0,99
23	1339027	69,21%	-7,46%	79,24	8,75	78,60	8,48	-10,03	0,87
24	1339038	98,86%	7,25%	156,53	11,58	154,42	11,32	-18,12	0,90
25	1339044	116,51%	-21,93%	160,62	35,14	160,00	30,11	-17,99	0,09
26	1439006	23,13%	-19,70%	27,57	26,16	26,70	22,74	0,06	0,16
<b>Média</b>		<b>21,64%</b>	<b>-4,75%</b>	<b>43,56</b>	<b>10,09</b>	<b>42,74</b>	<b>9,03</b>	<b>-2,78</b>	<b>0,78</b>

Fonte: Autor.

A Tabela 16 mostra que, após a aplicação do  $f_{cv (reg)}$ , apenas 6 estações apresentaram piora nos indicadores estatísticos, enquanto as demais apresentaram melhora, mas com desempenho geral inferior à correção de viés anterior. Quanto ao PBIAS, 12 estações apresentaram viés maior que 10% para mais ou para menos. O valor médio dos indicadores RMSE e MAE também aumentou em relação à correção de viés anterior, sendo 15,46 mm/h e 14,41 mm/h respectivamente. O coeficiente NSE médio também piorou, caindo para 0,45.

**Tabela 16 - Resultados obtidos pelos indicadores estatísticos de desempenho após a aplicação do  $f_{cv (reg)}$**

N	Código	PBIAS		RMSE (mm/h)		MAE (mm/h)		NSE	
		Estimado	Corrigido	Estimado	Corrigido	Estimado	Corrigido	Estimado	Corrigido
1	1439023	31,48%	-8,97%	41,22	12,04	41,02	11,69	-4,02	0,57
2	1439044	-11,74%	-20,79%	14,79	24,87	13,39	23,72	0,62	-0,07
3	1439089	23,60%	-2,25%	26,43	2,48	25,90	2,46	0,10	0,99
4	1539002	59,53%	10,51%	69,72	12,27	69,10	12,20	-9,08	0,69
5	1539006	14,58%	-6,09%	18,34	7,54	17,29	7,22	0,14	0,85
6	1539010	57,04%	9,73%	61,92	12,70	61,91	10,56	-2,60	0,85
7	1539014	19,32%	-5,31%	21,22	5,99	21,16	5,82	0,23	0,94
8	1639000	-0,37%	-14,18%	3,42	19,64	2,98	18,79	0,97	0,06
9	1739001	28,00%	-3,69%	46,19	6,53	44,62	5,87	-0,46	0,97
10	1739005	14,96%	1,73%	20,47	5,40	19,01	4,85	-0,82	0,87
11	1739010	4,72%	-19,80%	7,29	30,54	7,25	30,40	0,93	-0,21
12	1740001	-17,99%	6,97%	24,33	12,43	24,24	10,68	-0,73	0,55
13	1740005	-11,38%	7,67%	14,43	9,41	13,74	9,26	0,46	0,77
14	1740006	-13,26%	-5,41%	16,52	6,97	16,11	6,57	0,21	0,86
15	1740008	-26,71%	-8,61%	34,38	12,75	33,12	10,99	-2,16	0,56
16	1839000	-1,40%	12,21%	6,52	20,93	5,45	17,84	0,96	0,57
17	1840012	-22,57%	-5,83%	35,28	12,29	35,12	9,64	-0,15	0,86
18	1539016	-21,50%	-30,45%	28,70	39,50	26,57	37,64	-0,82	-2,44
19	1439002	47,48%	21,17%	43,45	19,52	42,59	18,99	-0,02	0,79
20	1539008	-24,15%	-34,00%	31,49	43,63	29,69	41,81	-0,45	-1,78
21	1339000	47,64%	0,63%	55,06	0,73	54,47	0,72	-4,45	1,00
22	1339012	57,78%	-13,50%	87,52	21,45	86,76	20,27	-5,08	0,63
23	1339027	69,21%	15,52%	79,24	17,69	78,60	17,63	-10,03	0,45
24	1339038	98,86%	-4,27%	156,53	6,69	154,42	6,67	-18,12	0,97
25	1339044	116,51%	11,73%	160,62	19,16	160,00	16,12	-17,99	0,73
26	1439006	23,13%	-12,75%	27,57	18,96	26,70	16,26	0,06	0,56
<b>Média</b>		<b>21,64%</b>	<b>-3,77%</b>	<b>43,56</b>	<b>15,46</b>	<b>42,74</b>	<b>14,41</b>	<b>-2,78</b>	<b>0,45</b>

Fonte: Autor.

A Tabela 17 apresenta, de forma resumida, os resultados obtidos pelos indicadores estatísticos PBIAS e NSE para os dados originais do CHIRPS (Estimado), após a aplicação do  $f_{cv}$  (corrigido (1)) e após aplicação do  $f_{cv (reg)}$  (corrigido (2)).

**Tabela 17 – Classificação dos resultados obtidos pelos indicadores estatísticos de desempenho PBIAS e NSE**

Classes	PBIAS			NSE		
	Estimado	Corrigido (1)	Corrigido (2)	Estimado	Corrigido (1)	Corrigido (2)
Muito bom	3	13	5	3	19	12
Bom	0	8	9	0	1	2
Satisfatório	5	2	6	1	2	6
Aceitável	-	-	-	1	0	1
Insatisfatório	18	3	6	21	4	5

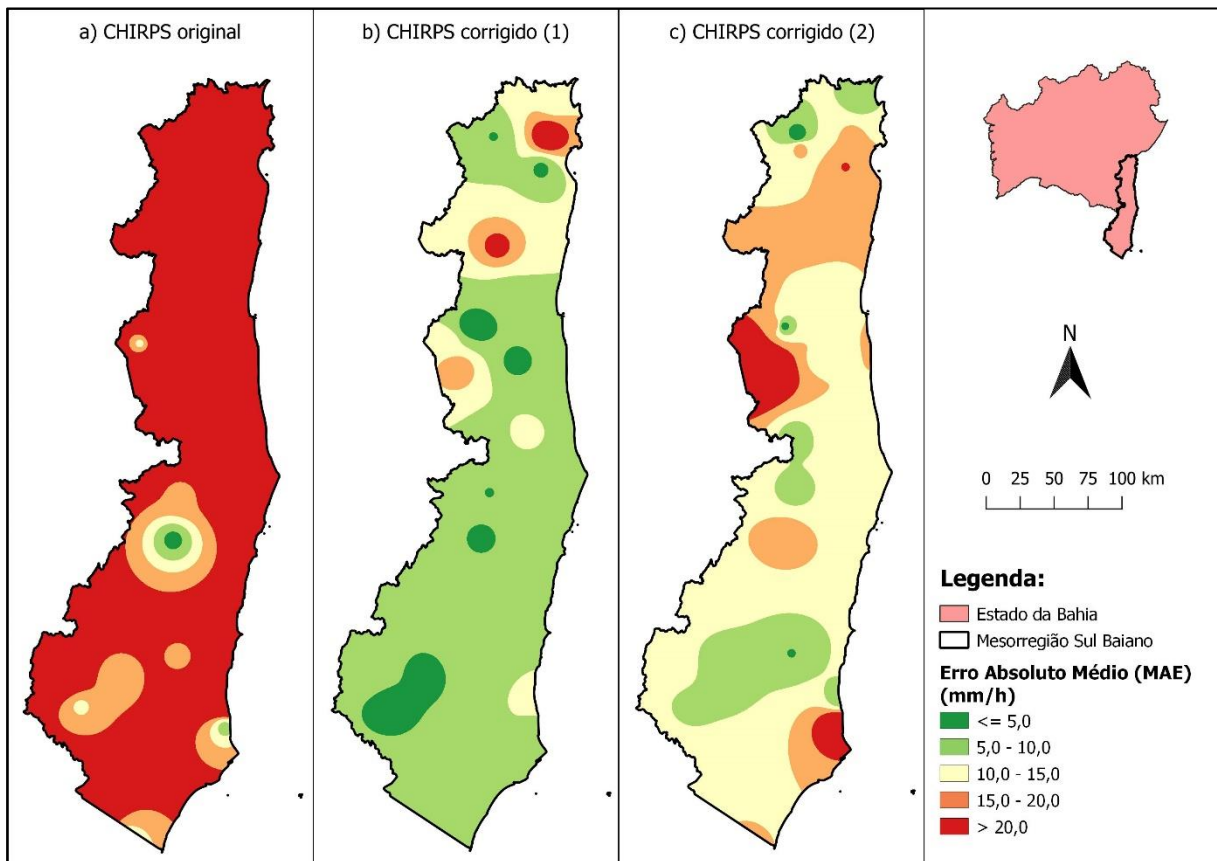
Fonte: Autor.

O indicador NSE (Tabela 17) revela que o desempenho dos dados originais estimados pelo CHIRPS foi insatisfatório em 21 das 26 estações analisadas. Já para os dados corrigidos (1), esse número caiu para 4, enquanto dezenove estações apresentaram desempenho muito bom. Isso demonstra que os dados do CHIRPS não apresentam desempenho suficiente em seu estado original para aplicação no desenvolvimento de curvas IDF na Mesorregião Sul Baiano, no entanto, podem ser utilizados após a correção do viés.

Já para os dados corrigidos (2), o desempenho foi inferior em relação ao corrigido (1), mas, ainda assim, houve uma melhora significativa em relação aos dados originais, apresentando desempenho insatisfatório em apenas 5 estações e muito bom em 12. Desse modo, na ausência de dados de campo, a correção de viés pode ser realizada, com uma certa limitação, utilizando apenas as coordenadas geográficas (latitude e longitude), em graus decimais, como parâmetros, conforme Equação 19.

A Figura 9 apresenta visualmente o Erro Absoluto Médio (MAE) encontrado para os dados estimados pelo CHIRPS (a) em relação aos dados observados nas estações de campo, bem como após aplicação do  $f_{cv}$  (b) e do  $f_{cv(reg)}$  (c). Dessa forma, é possível identificar as áreas onde a correção de viés não é tão efetiva.

Figura 9 - MAE para os dados do CHIRPS: a) Original, b) Corrigidos (1) e c) Corrigidos (2)



Fonte: Autor.

Visando comparar o desempenho obtido pelas IDF's após aplicação da correção de viés proposta ( $f_{cv (reg)}$ ) com uma das práticas comuns para obtenção de IDF's para áreas não monitoradas do Estado da Bahia, os resultados foram comparados com IDF's obtidas pelo Plúvio 2.1 (Tabela 18). De modo geral, os dados corrigidos (2) apresentaram melhor performance que os dados do Plúvio para todos os indicadores, tendo desempenho superior em 20 estações e inferior em apenas 6.

**Tabela 18 - Comparação entre o desempenho obtido pelas IDFs fornecidas pelo Plúvio e as IDFs estimadas pelo CHIRPS após aplicação do  $f_{CV(Reg)}$  (Corrigido 2)**

N	Código	PBIAS		RMSE (mm/h)		MAE (mm/h)		NSE	
		Plúvio	Corrigido 2	Plúvio	Corrigido 2	Plúvio	Corrigido 2	Plúvio	Corrigido 2
1	1439023	10,63%	-8,97%	16,71	12,04	14,29	11,69	0,17	0,57
2	1439044	25,30%	-20,79%	30,49	24,87	28,87	23,72	-0,61	-0,07
3	1439089	30,27%	-2,25%	34,37	2,48	33,22	2,46	-0,52	0,99
4	1539002	23,10%	10,51%	28,93	12,27	26,82	12,20	-0,74	0,69
5	1539006	4,11%	-6,09%	6,75	7,54	5,80	7,22	0,88	0,85
6	1539010	13,80%	9,73%	15,44	12,70	14,97	10,56	0,78	0,85
7	1539014	12,74%	-5,31%	16,12	5,99	13,96	5,82	0,56	0,94
8	1639000	-6,83%	-14,18%	9,07	19,64	9,06	18,79	0,80	0,06
9	1739001	-13,91%	-3,69%	22,21	6,53	22,18	5,87	0,66	0,97
10	1739005	7,98%	1,73%	13,41	5,40	11,57	4,85	0,22	0,87
11	1739010	-10,55%	-19,80%	18,32	30,54	16,20	30,40	0,56	-0,21
12	1740001	18,04%	6,97%	26,72	12,43	24,31	10,68	-1,08	0,55
13	1740005	25,26%	7,67%	32,32	9,41	30,50	9,26	-1,71	0,77
14	1740006	24,65%	-5,41%	32,09	6,97	29,96	6,57	-1,98	0,86
15	1740008	21,98%	-8,61%	28,88	12,75	27,25	10,99	-1,23	0,56
16	1839000	45,66%	12,21%	67,25	20,93	66,72	17,84	-3,48	0,57
17	1840012	68,04%	-5,83%	108,93	12,29	105,84	9,64	-10,01	0,86
18	1539016	15,67%	-30,45%	20,73	39,50	19,37	37,64	0,05	-2,44
19	1439002	59,41%	21,17%	54,92	19,52	53,29	18,99	-0,63	0,79
20	1539008	16,28%	-34,00%	20,17	43,63	20,01	41,81	0,40	-1,78
21	1339000	2,04%	0,63%	3,29	0,73	2,81	0,72	0,98	1,00
22	1339012	-22,52%	-13,50%	35,20	21,45	33,81	20,27	0,02	0,63
23	1339027	2,74%	15,52%	4,13	17,69	3,55	17,63	0,97	0,45
24	1339038	-25,02%	-4,27%	39,39	6,69	39,08	6,67	-0,21	0,97
25	1339044	-15,29%	11,73%	26,75	19,16	22,65	16,12	0,47	0,73
26	1439006	18,85%	-12,75%	21,81	18,96	21,76	16,26	0,41	0,56
<b>Média</b>		<b>13,56%</b>	<b>-3,77%</b>	<b>28,25</b>	<b>15,46</b>	<b>26,84</b>	<b>14,41</b>	<b>-0,55</b>	<b>0,45</b>

Fonte: Autor.

A Tabela 19 apresenta, de forma resumida, os resultados obtidos pelos indicadores estatísticos PBIAS e NSE para os dados do CHIRPS após aplicação do  $f_{CV(Reg)}$  (corrigido (2)), em comparação com os dados interpolados pelo Plúvio.

**Tabela 19 - Classificação dos resultados obtidos pelos indicadores estatísticos de desempenho PBIAS e NSE da Tabela 18**

Classes	PBIAS		NSE	
	Plúvio	Corrigido (2)	Plúvio	Corrigido (2)
Muito bom	3	5	5	12
Bom	2	9	1	2
Satisfatório	5	6	2	6
Aceitável	-	-	3	1
Insatisfatório	16	6	15	5

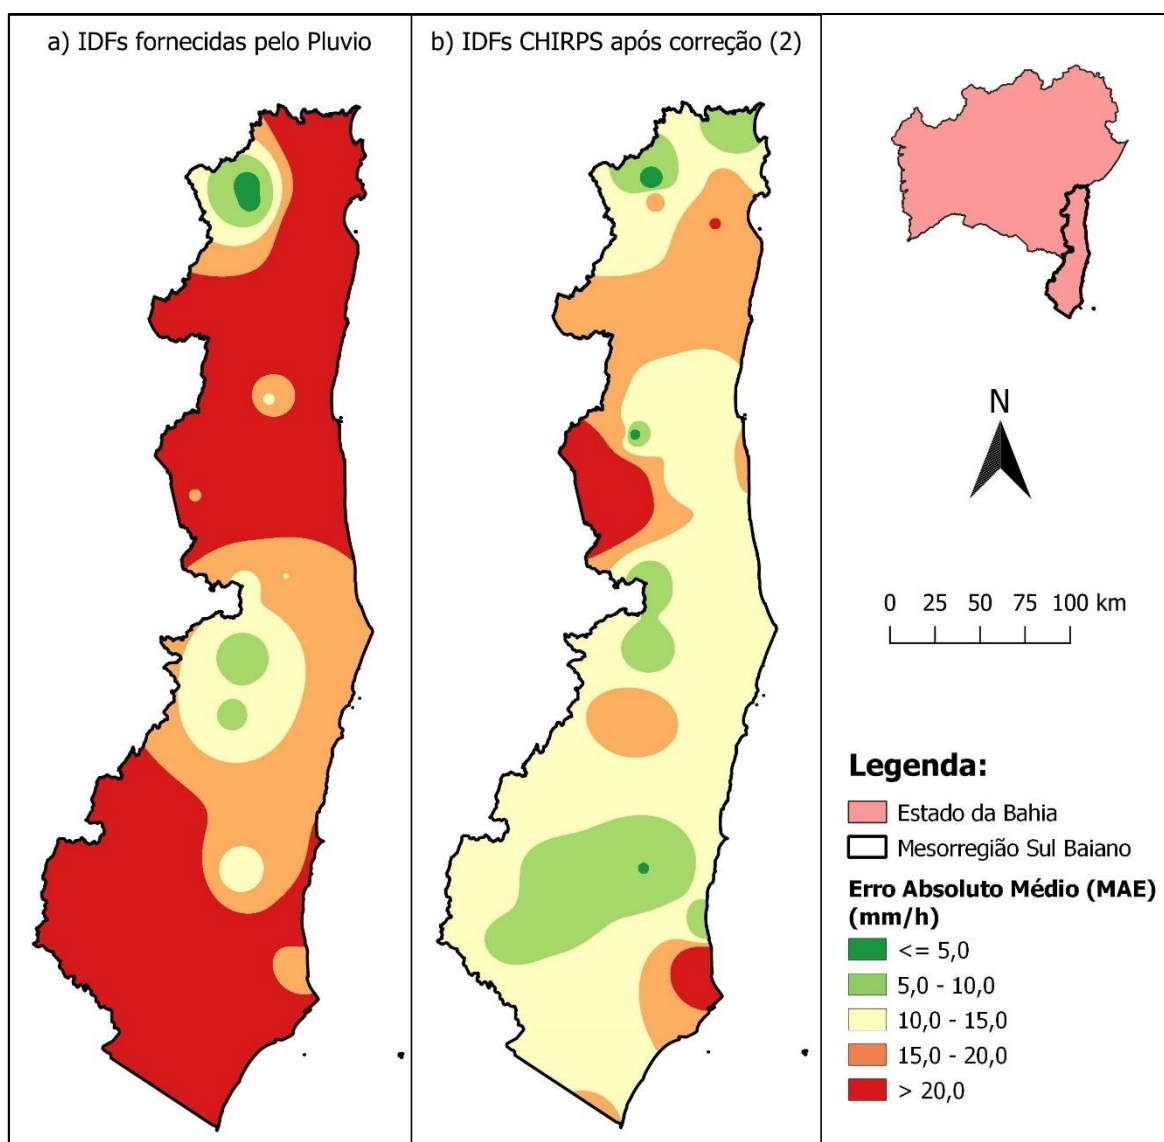
Fonte: Autor.

Considerando o indicador NSE, os dados corrigidos (2) apresentaram resultado muito bom em 12 estações e insatisfatório em apenas 5, enquanto os dados do Plúvio

apresentaram resultado muito bom em apenas 5 estações e insatisfatório em 15. Esta análise indica que a utilização dos dados do CHIRPS após aplicação do  $f_{cv(reg)}$  pode ser mais recomendada que a utilização de IDFs interpoladas pelo Plúvio na área de estudo.

A Figura 10 apresenta visualmente o Erro Absoluto Médio (MAE) encontrado para os dados estimados pelas IDFs fornecidas pelo Plúvio (a) em relação às IDFs estimadas pelo CHIRPS após aplicação do  $f_{cv(reg)}$  (b).

**Figura 10 – Interpolação do MAE para a) IDFs fornecidas pelo Plúvio e b) Estimadas pelo CHIRPS após correção de viés (2)**



Fonte: Autor.

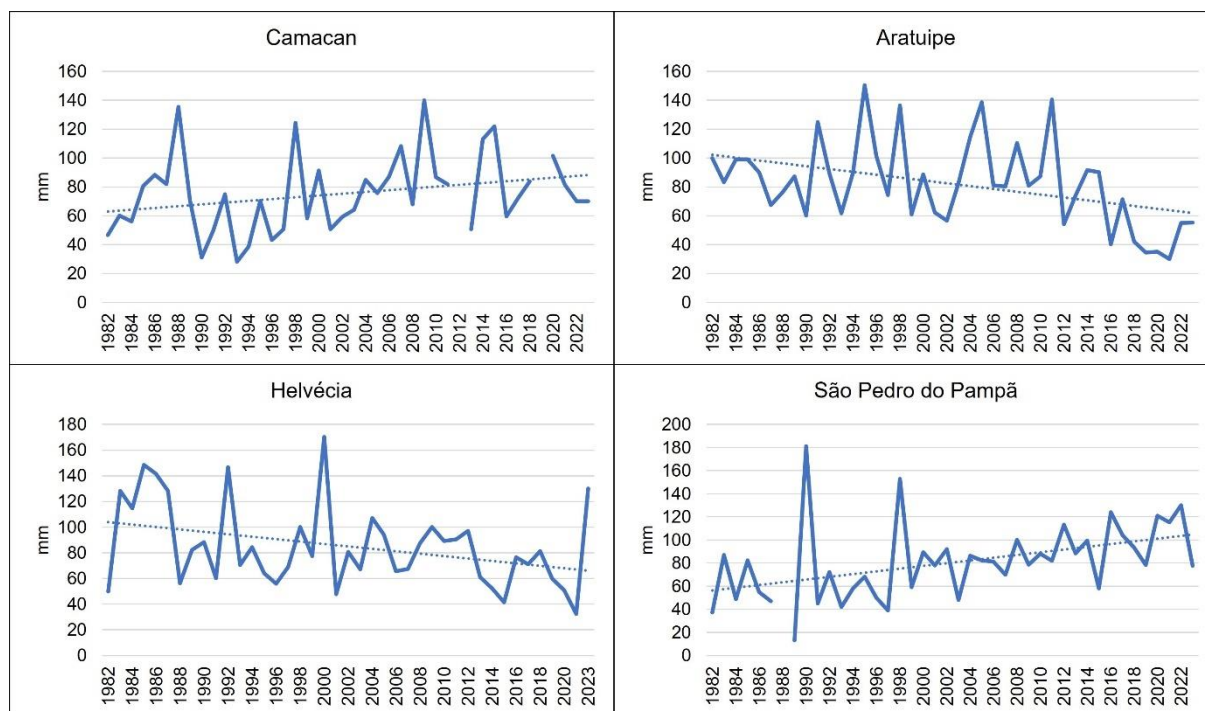
### 5.3. Análise de frequência sob hipótese de não estacionariedade

Nesta etapa, as séries temporais das estações que apresentaram tendência nas etapas anteriores foram exploradas através de uma análise estatística mais aprofundada, visando testar a aplicação de modelos não estacionários.

#### 5.3.1. Análises estatísticas

A Figura 11 apresenta os gráficos das séries temporais de precipitação máxima diária anual das quatro estações analisadas, com as respectivas linhas de tendência. A inclinação das retas observadas no gráfico sugere uma tendência linear positiva nas estações de Camacan (Vargito) e São Pedro do Pampã, e negativa nas estações de Aratuípe e Helvécia (EFBM) (ver Quadro 7 no APÊNDICE A).

Figura 11 - Séries de PMDA com as respectivas linhas de tendência



Fonte: Autor.

A fim de verificar a significância estatísticas dessas tendências, foram aplicados testes de tendência e mudanças abruptas nas séries. Para isso, inicialmente, foi feita uma análise exploratória dos dados através de medidas descritivas (Tabela 20).

**Tabela 20 - Resumo das análises estatísticas**

Estatísticas		Camacan	Aratuípe	Helvecia	São Pedro do Pampã
	Mínimo	28	30	32,4	13
	Mediana	71,25	81,85	80,7	81,2
	Máximo	140	150,4	170,2	181
Testes					
Shapiro-Wilk	Estimativa	0,96	0,97	0,94	0,96
	p-valor	0,18	0,26	0,03	0,18
Box test	Estimativa	0,74	3,30	0,43	1,12
	p-valor	0,39	0,07	0,51	0,29
Mann-Kendall	Estimativa	1,98	-2,95	-1,94	3,73
	p-valor	0,048	0,003	0,052	0,0002
CUSUM	Estimativa	1,30	2,02	1,15	1,55
	p-valor	0,07	0,001	0,14	0,02
Soma dos ranks	Estimativa	107	299	250	71,5
	p-valor	0,01	0,003	0,27	0,001

Fonte: Autor.

A Tabela 21 apresenta a interpretação dos resultados das análises estatísticas. Os resultados do teste de Shapiro-Wilk indicaram que os dados de três das séries analisadas apresentam distribuição normal. Esta condição permite a aplicação de testes e modelos com exigência de normalidade nos dados, no entanto, foram aplicados testes não paramétricos, visando a aplicação de modelagem probabilística sem remoção da condição de tendência nas séries.

Através do Box test, foi identificado que todas as séries analisadas apresentam dados independentes, o que permite a aplicação do teste de Mann-Kendall. Após a aplicação do teste, a tendência foi confirmada em três das quatro estações: Camacan, Aratuípe e São Pedro do Pampã. Na estação de Helvecia, que havia apresentado tendência nas etapas anteriores do estudo, essa condição não foi confirmada. Ressalta-se que, nesta etapa, foi acrescentado o dado de PMDA do ano de 2023 e a série passou a ser de 1982 a 2023. Possivelmente, a adição deste dado provocou uma mudança na série, que deixou de apresentar tendência ao nível de significância estatística de 5%. Este resultado reforça a importância de monitorar a qualidade dos registros de precipitação, uma vez que qualquer alteração na série, que pode ser causada por falha ou inconsistência nos dados, pode mascarar os resultados.

**Tabela 21 - Interpretação dos resultados da Tabela 20**

Interpretação	Teste	Camacan	Aratupe	Helvecia	São Pedro do Pampã
A distribuição é normal?	Shapiro-wilk	sim	sim	não	sim
Os dados são independentes?	Box test	sim	sim	sim	sim
A série apresenta tendência?	Mann-Kendall	sim	sim	não	sim
Houve mudança abrupta?	CUSUM	não	sim	não	sim
Possível ano de mudança		-	2011	-	1997
Há diferença significativa entre os dois períodos?	Soma dos ranks	-	sim	-	sim

Fonte: Autor.

A série de Camacan apresenta tendência, mas não foi identificada mudança abrupta ao nível de significância de 5%. Assim, no ajuste dos modelos não estacionários, foi considerada uma tendência linear monotônica positiva a partir do ano inicial da série (1982).

Quanto a série de Aratupe, a tendência foi confirmada pelo teste de Mann-kendall, com identificação de mudança abrupta a partir do ano de 2011 pelo teste de CUSUM. Além disso, foi identificada diferença significativa entre os dois períodos quando a série foi dividida e o teste de soma dos ranks foi aplicado. Portanto, foi considerada uma tendência linear negativa a partir do ano de 2011.

No caso da série de Helvecia, não foi identificada tendência nem mudanças abruptas. Portanto, os modelos estacionários podem ser aplicados, sem necessidade de testar os modelos não estacionários.

Quanto a série de São Pedro do Pampã, a tendência foi confirmada pelo teste de Mann-kendall, com identificação de mudança abrupta a partir do ano de 1997 pelo teste de CUSUM. Além disso, foi identificada diferença significativa entre os dois períodos quando a série foi dividida e o teste de soma dos ranks foi aplicado. Portanto, foi considerada uma tendência linear positiva a partir do ano de 1997.

### 5.3.2. Escolha do modelo

Após a aplicação dos testes, foram ajustadas as distribuições de GEV e Gumbel, tanto a partir de modelos tradicionais (estacionários), quanto modelos não estacionários (parâmetro de posição variando no tempo).

Os resultados a seguir apresentam os parâmetros estimados para cada um dos modelos aplicados às séries de Camacan (Tabela 22), Aratupe (Tabela 23), Helvecia (Tabela 24) e São Pedro do Pampã (Tabela 25), bem como o resultado dos critérios de seleção AIC, BIC e do teste da Razão de Verossimilhança (RV).

**Tabela 22 - Estimativas dos parâmetros das distribuições e critérios de seleção para Camacan**

Distribuição		Estimativas	AIC	BIC	RV	Seleção
GEV	$\mu$	63,96	378,70	383,77	3,8415 (p=0,425)	Gumbel
	$\sigma$	22,98				
	$\xi$	-0,10				
Gumbel	$\mu$	62,77	377,34	380,71		
	$\sigma$	22,40				
Distribuição		Estimativas	AIC	BIC		
GEV (não estacionário)	$\mu_0$	47,44	374,37	381,13	6,9552 (p=0,0084)	Gumbel
	$\mu_1$	0,82				
	$\sigma$	19,93				
	$\xi$	0,01				
Gumbel (não estacionário)	$\mu_0$	47,56	372,38	377,45		
	$\mu_1$	0,82				
	$\sigma$	20,01				

Fonte: Autor.

Os resultados da Tabela 22 revelam que a distribuição de Gumbel apresentou os menores valores dos critérios AIC e BIC, sendo mais apropriado para dados de precipitação de Camacan. Isso foi confirmado através do teste da razão de verossimilhança, que ratificou a escolha do modelo com menor número de parâmetros. Na comparação entre os modelos Gumbel estacionário e não estacionário, verificou-se através do teste de razão de verossimilhança que o modelo com maior número de parâmetros prevalece (p-valor: 0,017), sendo este o modelo Gumbel não estacionário.

**Tabela 23 - Estimativas dos parâmetros das distribuições e critérios de seleção para Aratuípe**

Distribuição		Estimativas	AIC	BIC	RV	Seleção
GEV	$\mu$	70,43	406,32	411,53	1,7403 ( $p=0,1871$ )	Gumbel
	$\sigma$	2,98				
	$\xi$	-0,21				
Gumbel	$\mu$	68,18	406,06	409,54		
	$\sigma$	25,55				
Distribuição		Estimativas	AIC	BIC		
GEV (não estacionário)	$\mu_0$	78,97	386,41	393,36	0,016614 ( $p=0,8974$ )	Gumbel
	$\mu_1$	-4,25				
	$\sigma$	18,37				
	$\xi$	0,02				
Gumbel (não estacionário)	$\mu_0$	79,23	384,43	389,64		
	$\mu_1$	-4,29				
	$\sigma$	18,52				

Fonte: Autor.

Os resultados foram semelhantes para a estação de Aratuípe, conforme a Tabela 23, onde o modelo Gumbel não estacionário também foi escolhido pelos critérios AIC, BIC e RV ( $p$ -valor:  $1,166E-06$ ). No entanto, para a análise de frequência, é prudente a utilização do modelo estacionário, uma vez que a série apresenta uma tendência linear negativa, e a utilização da abordagem não estacionária pode levar a um subdimensionamento das estruturas hidráulicas, que podem perder a sua capacidade de suporte ao longo dos anos caso os padrões de chuva se alterem novamente.

**Tabela 24 - Estimativas dos parâmetros das distribuições e critérios de seleção para Helvécia**

Distribuição		Estimativas	AIC	BIC	RV	Seleção
GEV	$\mu$	70,28	399,45	404,59	0,018918 ( $p=0,8906$ )	Gumbel
	$\sigma$	24,66				
	$\xi$	0,018				
Gumbel	$\mu$	70,52	397,47	400,89		
	$\sigma$	24,81				

Fonte: Autor.

Conforme os resultados da Tabela 24, a distribuição de Gumbel também foi selecionada pelos critérios adotados na estação de Helvécia, onde foram testados apenas modelos estacionários devido à ausência de tendência na série.

**Tabela 25 - Estimativas dos parâmetros das distribuições e critérios de seleção para São Pedro do Pampã**

Distribuição		Estimativas	AIC	BIC	RV	Seleção
GEV	$\mu$	67,37	404,80	409,94	1,2272 (p=0,2679)	Gumbel
	$\sigma$	28,61				
	$\xi$	-0,11				
Gumbel	$\mu$	65,69	404,03	407,46		
	$\sigma$	28,17				
Distribuição		Estimativas	AIC	BIC		
GEV (não estacionário)	$\mu_0$	51,81	389,90	396,75	0,0002088 (p=0,9885)	Gumbel
	$\mu_1$	1,95				
	$\sigma$	22,04				
	$\xi$	0,0012				
Gumbel (não estacionário)	$\mu_0$	51,82	387,90	393,04		
	$\mu_1$	1,95				
	$\sigma$	22,05				

Fonte: Autor.

Conforme a Tabela 25, o modelo Gumbel não estacionário também foi selecionado na estação de São Pedro do Pampã pelos critérios AIC, BIC e RV (p-valor: 2,061E-05), uma vez que a série apresenta uma tendência linear positiva.

A fim de ilustrar, de forma aplicada, como a seleção do modelo interfere nos resultados da análise de frequência, foram calculadas as chuvas máximas diárias (mm) para os tempos de retorno (TR) de 2 anos e 20 anos nas estações de Camacan e São Pedro do Pampã, visto que o modelo não estacionário foi selecionado para ambas. Enquanto para Aratupe e Helvecia, as chuvas foram calculadas apenas pelo modelo estacionário.

Primeiramente foi calculada a chuva pelos modelos de Gumbel e GEV estacionários. Quanto aos modelos não estacionários, a chuva calculada se altera ao longo dos anos, visto que os parâmetros das distribuições variam ao longo do tempo. Assim, a Tabela 26 mostra a chuva calculada ao fim do período histórico da série de Camacan. Além disso, foi calculada também a chuva projetada para um horizonte de 30 anos além do período histórico, pelo modelo GEV.

**Tabela 26 - Chuva máxima diária (mm) calculada pelos modelos para os TR de 2 e 20 anos na estação de Camacan**

Distribuição	TR (anos)	Modelo estacionário	Modelo não estacionário (período histórico - 2023)	Modelo não estacionário (projeção de 30 anos - 2053)
Gumbel	2	70,98	86,92 (+22,46%)	
	20	129,3	139,03 (+7,53%)	
GEV	2	72,23	86,85 (+20,24%)	111,53 (+54,41%)
	20	123,07	139,67 (+13,49%)	164,35 (+33,54%)

Fonte: Autor.

Nota-se, a partir dos resultados da Tabela 26, que as diferenças entre os valores de chuva calculados pelas distribuições de Gumbel e GEV são mínimas. Portanto, pode-se inferir que a distribuição de Gumbel foi escolhida em todos os casos por ser o modelo com menor número de parâmetros, uma vez que os critérios de seleção avaliam se os dados fornecem evidências suficientes para rejeitar o modelo mais simples (Gumbel) em favor do modelo mais complexo (GEV). Assim, como não houve diferenças significativas, a utilização de um modelo mais complexo não se justifica. Entretanto, as diferenças são mais expressivas na comparação entre os modelos estacionários e não estacionários. Por exemplo, a chuva com tempo de retorno de 2 anos calculada pelo modelo Gumbel estacionário é de 70,98 mm, enquanto a calculada pelo modelo Gumbel não estacionário é de 86,92 mm ao final do período histórico, sendo 22,46% maior.

Para ilustrar o dimensionamento de uma estrutura hidráulica com vida útil de 30 anos, foi calculada a chuva projetada com tempos de retorno de 2 anos e 20 anos pelo modelo GEV não estacionário. O resultado para o TR de 2 anos é de 111,53 mm, sendo 28,42% maior que a chuva calculada pelo modelo GEV não estacionário para o período histórico, e 54,41% maior que a chuva calculada pelo modelo estacionário.

A Tabela 27 apresenta os resultados análogos para a estação de São Pedro do Pampã, onde as diferenças entre os modelos estacionários e não estacionários foram ainda mais expressivas, com aumento na chuva calculada chegando a 45,36% para o período histórico e até 117,46% para a projeção de 30 anos.

**Tabela 27 - Chuva máxima diária (mm) calculada pelos modelos para os TR de 2 e 20 anos na estação de São Pedro do Pampã**

Distribuição	TR (anos)	Modelo estacionário	Modelo não estacionário (período histórico - 2023)	Modelo não estacionário (projeção de 30 anos - 2053)
Gumbel	2	76,01	110,49 (+45,36%)	
	20	149,36	167,90 (+12,41%)	
GEV	2	77,65	110,48 (+42,28%)	168,86 (+117,46%)
	20	139,82	167,99 (+20,15%)	193,87 (+38,66)

Fonte: Autor.

A Tabela 28 apresenta as chuvas máximas diárias (mm) calculadas pelos modelos estacionários para os tempos de retorno (TR) de 2 anos e 20 anos nas estações de Aratuípe e Helvécia. De forma análoga, observa-se diferenças mínimas entre os valores calculados pelas distribuições de Gumbel e GEV.

**Tabela 28 - Chuva máxima diária (mm) calculada pelos modelos estacionários para os TR de 2 e 20 anos nas estações de Aratuípe e Helvécia**

Distribuição	TR (anos)	Aratuípe	Helvécia
Gumbel	2	77,55	79,62
	20	144,08	144,22
GEV	2	79,86	79,35
	20	132,76	145,51

Fonte: Autor.

## 6. CONCLUSÕES

Neste estudo, os dados de precipitação estimados por satélite derivados do produto CHIRPS foram avaliados para determinar sua capacidade de desenvolver curvas IDF na Mesorregião Sul Baiano, levando principalmente às seguintes conclusões:

- Os resultados iniciais indicaram que o produto, em seu estado original, não apresentou desempenho satisfatório para o desenvolvimento de curvas IDF na área de estudo (PBIAS 21,54%; RMSE 43,56 mm/h; MAE 42,74 mm/h; NSE -2,78). No entanto, os resultados mostraram-se muito mais promissores quando o viés das estimativas do CHIRPS foi corrigido (PBIAS -4,75%; RMSE 10,09 mm/h; MAE 9,03 mm/h; NSE 0,78);
- Este estudo propôs um método de correção de viés baseado em um modelo de regressão linear, e os resultados (PBIAS -3,77%; RMSE 15,46 mm/h; MAE 14,41 mm/h; NSE 0,45) mostraram que, na ausência de dados observados em campo, a

correção de viés pode ser realizada para a área de estudo, com algumas limitações, utilizando apenas coordenadas geográficas (latitude e longitude);

- O desempenho foi comparado com as curvas IDF fornecidas pelo software Plúvio (PBIAS 13,56%; RMSE 28,25 mm/h; MAE 26,84 mm/h; NSE -0,55), amplamente utilizado por engenheiros/projetistas. Os resultados indicaram que a utilização de dados do CHIRPS após a aplicação do fator de correção de viés proposto neste trabalho (CV.2), apresentou potencial para geração de curvas IDF mais precisas que as curvas fornecidas pelo Plúvio na área de estudo, principalmente por incorporar dados atuais e combinar estimativas de satélite com dados de campo;
- As séries que apresentaram tendência, inviabilizando a determinação de curvas IDF, foram submetidas a análises estatísticas visando investigar a aplicabilidade de modelos de probabilidade adaptados para séries não estacionárias. Confirmou-se a hipótese de que os modelos não estacionários são mais apropriados quando a condição de tendência é identificada. Além disso, verificou-se que os modelos com menor número de parâmetros foram preferidos em relação aos modelos mais complexos, prevalecendo a distribuição de Gumbel em relação à distribuição GEV. Notadamente, as diferenças entre os valores de chuva calculados pelas distribuições de Gumbel e GEV foram mínimas. Portanto, pode-se inferir que a distribuição de Gumbel foi escolhida em todos os casos por ser o modelo com menor número de parâmetros, uma vez que os critérios de seleção avaliam se os dados fornecem evidências suficientes para rejeitar o modelo mais simples (Gumbel) em favor do modelo mais complexo (GEV). Assim, como não houve diferenças significativas, a utilização de um modelo mais complexo não se justifica.
- Observou-se diferenças significativas entre a chuva máxima diária calculada pelo modelo estacionário e pelos modelos não estacionários para os tempos de retorno de 2 e 20 anos, com aumento na chuva calculada de até 45,36% para o período histórico (2023) e até 117,46% para a projeção de 30 anos (2053), na estação São Pedro do Pampã. Essa discrepância reforça a importância da análise de tendências nas séries históricas de precipitação visando subsidiar a escolha do modelo adequado para análise de frequência e, conseqüentemente, o dimensionamento de estruturas hidráulicas mais resilientes em busca de adaptação às alterações climáticas.

Estudos futuros podem avaliar diferentes produtos de precipitação por satélite e comparar os resultados. Uma outra limitação dos produtos de satélite, que não foi abordada neste estudo e pode ser considerada em estudos futuros se refere à incerteza associada às diferenças de escala, quando os dados de satélite são extraídos através do método *point-to-pixel*, onde o valor médio de precipitação em uma área espacial maior é comparado ao valor medido em um ponto da superfície pela estação pluviométrica. Além disso, a análise de frequência realizada neste trabalho pode ser complementada, partindo para a aplicação de métodos adaptados a condições de não estacionariedade, como o *Design Life Level* (DLL), introduzido por Rootzén e Katz (2013).

O presente estudo buscou aplicar os conceitos voltados à análise de não estacionariedade para projetos de drenagem urbana, no entanto, recomenda-se também, para estudos futuros, a aplicação desses conceitos para o dimensionamento de estruturas maiores, como barragens e pontes. Essas estruturas naturalmente apresentam maior risco associado e, portanto, demandam maior segurança. Além disso, muitas vezes são projetadas com maior vida útil, considerando a sua dimensão e o custo envolvido na sua construção. Dessa forma, a análise de tendência e a utilização de modelos não estacionários são ainda mais importantes no dimensionamento dessas estruturas.

O aprimoramento das curvas IDF abordado neste trabalho contribui para projetos mais confiáveis de estruturas hidráulicas, mas é importante reconhecer que isso é apenas parte da solução. Para melhorar a gestão do risco de inundações e alcançar sistemas mais resilientes a eventos extremos, outros aspectos devem ser considerados, como soluções sustentáveis de drenagem urbana, avanços na previsão meteorológica e em sistemas de alerta de inundações, bem como o aumento da sensibilização da comunidade sobre riscos.

## REFERÊNCIAS

- ABREU, M. C.; CECÍLIO, R. A.; PRUSKI, F. F.; ALMEIDA, L. T.; SANTOS, G. R.; ZANETTI, S. S.; PEREIRA, S. B.; SILVA, D. D. Daily rainfall disaggregation to estimate the intensity-duration-frequency relationship in Minas Gerais state, Brazil. **Engineering, Technology and Techniques**, v.65, 2022.
- ADLER, R.F.; HUFFMAN, G.J.; CHANG, A.; FERRARO, R.; XIE, P.-P.; JANOWIAK, J.; RUDOLF, B.; SCHNEIDER, U.; CURTIS, S.; BOLVIN, D.; GRUBER, A.; SUSSKIND, J.; ARKIN, P.; NELKIN, E. The Version-2 Global Precipitation Climatology Project (GPCP) monthly precipitation analysis (1979–present). **J. Hydrometeorol.** V.4, n.6, p.1147–1167, 2003. Disponível em: [https://doi.org/10.1175/1525-7541\(2003\)004<1147:TVGPCP>2.0.CO;2](https://doi.org/10.1175/1525-7541(2003)004<1147:TVGPCP>2.0.CO;2).
- AGUIAR, P.C.B. Breve panorama econômico e socioterritorial recente da região Cacaueira do Sul do Estado da Bahia, Brasil. **Investig. Geogr. Chile**, 55: 37-58, 2018.
- ALEXANDRE, G.; BAPTISTA, M.; NAGHETTINI, M. Estudo para Identificação de Tendências do Regime Pluvial na Região Metropolitana de Belo Horizonte a Partir de Métodos Estatísticos. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 15, n. 2, pp. 115-126, 2010.
- ALVARES, C.A.; STAPE, J.L.; et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.
- ANA - Agência Nacional de Águas e Saneamento Básico. Operação e modernização da rede hidrometeorológica nacional, coordenada pela ANA, para atendimento das salas de situação da ANA e dos Estados. Brasília-DF, 2013, 76p.
- ANJINHO, P. S.; RUEZZENE, C. B.; ROQUE, R. C.; PARIZOTTO, D.; BOLLETI, T. M.; BUENO, L. O.; SANTOS, A. R.; VALADÃO, C. C.; BARBOSA, M. G. A.; MAUAD, F. F. Análise da acurácia dos dados de precipitação obtido pelo produto CHIRPS. XXIV Simpósio brasileiro de recursos hídricos, 2021.
- ARAGÃO, R.; COSTA, F. F.; RUFINO, I. A. A.; RAMOS FILHO, R. da S.; SRINIVASAN, V. S.; TRUTA NETO, J. D. B. Intensity-Duration-Frequency equations (IDF) for the state of Paraíba, Brazil, and regionalization of its parameters. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 28, n. 10, 2024. Disponível em: <https://doi.org/10.1590/1807-1929/agriambi.v28n10e283679>.
- AYOADE, J. O. **Introdução à climatologia para os trópicos**. Rio de Janeiro: Bertrand Brasil, 2003, 332p.
- BACELAR, L.; FERREIRA, R.; COSTA, I.; RODRIGUES, M.; CAMARGO, H.; LINDBERGH, S.; CARAM, R.; ANGELIS, C.F.; TOMASELLA, J.; DAMÉ, R.C.; TEIXEIRA, C. Limiares de chuva deflagradores de inundação brusca para bacias da Região Serrana do Rio de Janeiro: radar meteorológico versus pluviômetros. In: XX Simpósio Brasileiro de Recursos Hídricos, 2013, Bento Gonçalves-RS. **Anais eletrônicos**. Bento Gonçalves: ABRHidro, 2013. Disponível em: <https://anais.abrhidro.org.br/job.php?Job=1626>.

BACK, A. J. Relações intensidade-duração-freqüência de chuvas intensas de Chapecó, Estado de Santa Catarina. **Acta Scientiarum, Agronomy**, v.28, n.4, p.575-581, 2006.

BACK, A. J. Relações entre precipitações intensas de diferentes durações ocorridas no município de Urussanga, SC. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, n. 2, p. 170-175, 2009.

BACK, A. J.; HENN, A.; OLIVEIRA, J. L. R. Heavy rainfall equations for Santa Catarina, Brazil. **Revista Brasileira de Ciência do Solo**, v.35, p.2127-2134, 2011.

BACK, A. J.; OLIVEIRA, J. L. R.; HENN, A. Relações entre precipitações intensas de diferentes durações para desagregação da chuva diária em Santa Catarina. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.16, n.4, p.391-398, 2012.

BACK, A. J.; POLA, A. C. Relações entre precipitações intensas de diferentes durações de Videira, Santa Catarina. **Revista Tecnologia e Ambiente**, v.22, p.125-135, 2016.

BARBOSA, A. de G.; SOUZA NETO, I. R. de; COSTA, V. A. F.; MENDES, L. A. Assessing intensity-duration-frequency equations and spatialization techniques across the Grande River Basin in the state of Bahia, Brazil. **Revista Brasileira de Recursos Hídricos**, v. 27, 2022. Disponível em: <https://doi.org/10.1590/2318-0331.272220220083>.

BASSO, R. E. DANIEL GUSTAVO ALLASIA, D. G.; TASSI R.; PICKBRENNER, K. Revisão das isozonas de chuvas intensas do Brasil. **Engenharia Sanitária e Ambiental**, v.21, n.4, p.635-641, 2016.

BAYISSA, Y.; TADESSE, T.; DEMISSE, G.; SHIFERAW, A. Evaluation of satellite-based rainfall estimates and application to monitor meteorological drought for the Upper Blue Nile Basin, Ethiopia. **Remote Sensing**, v. 9, n. 669, 2017. Disponível em: <https://doi.org/10.3390/rs9070669>.

BECK, H.E.; WOOD, E.F.; PAN, M.; FISHER, C.K.; MIRALLES, D.G.; DIJK, A.I.J.M.V.; MCVICAR, T.R.; ADLER, R.F. MSWEP V2 Global 3-Hourly 0.1° Precipitation: Methodology and Quantitative Assessment. **Bulletin of the American Meteorological Society**, v.100, p.473-500, 2019. Disponível em: <https://doi.org/10.1175/BAMS-D-17-0138.1>.

BEMFICA, D. C.; GOLDENFUM, J. A.; SILVEIRA, A. L. L. da. Análise da aplicabilidade de padrões de chuva de projeto a Porto Alegre. **Revista Brasileira de Recursos Hídricos**, v.5 n.4, p.5-16, 2000.

BERNARDO, J. A.; TSUJI, T. M.; RECH, B.; UDA, P. K.; FINOTTI, A. R. Avaliação do produto CHIRPS na estimativa de eventos extremos de precipitação em Florianópolis/SC. *In: XXV Simpósio Brasileiro de Recursos Hídricos, 2023, Aracaju-SE. Anais eletrônicos*. Aracaju: ABRHidro, 2023. Disponível em: <https://anais.abrhidro.org.br/job.php?Job=15597>.

BESKOW, S.; CALDEIRA, T. L.; MELLO, C. R., FARIA, L. C.; GUEDES, H. A. S. Multiparameter probability distributions for heavy rainfall modeling in extreme southern Brazil. **Journal of Hydrology: Regional Studies**, v.4, p.123-133, 2015.

BINESH, N.; NIKSOKHAN, M. H.; SARANG A.; RAUCH, W. Improving sustainability of urban drainage systems for climate change adaptation using best management practices: A case study of Tehran, Iran. **Hydrological Sciences Journal**, v.64, n.4, p.381-404, 2019.

BLANCHET, J., MOLINIÉ, G., TOUATI, J. Spatial analysis of trend in extreme daily rainfall in southern France. **Climate Dynamics**, v.51, p.799-812, 2018. Disponível em: <https://doi.org/10.1007/s00382-016-3122-7>.

BRAGANÇA, N.; RODRIGUES, L.; MENDES, G.; MAGALHÃES, A.; TEIXIERA, P.; MEDEIROS, A.; AMÂNCIO, E.; MELO, D. Comparação entre vazões de projeto gerada pela IDF do Pluvio e Rio Águas na bacia da Zona dos Canais. *In*: XXV Simpósio Brasileiro de Recursos Hídricos, 2023, Aracaju-SE. **Anais eletrônicos**. Aracaju: ABRHidro, 2023. Disponível em: <https://anais.abrhidro.org.br/job.php?Job=15376>.

BURNHAM, K. P.; ANDERSON, D. R. Multimodel inference: understanding AIC and BIC in model selection. **Sociological Methods & Research**, v. 33, p. 261-304, 2004. Disponível em: <https://doi.org/10.1177/0049124104268644>.

CALDEIRA, T. L.; BESKOW, S.; MELLO, C. R.; FARIA, L. C.; DE SOUZA, M. R.; GUEDES, H. A. Modelagem probabilística de eventos de precipitação extrema no estado do Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental-Agriambi.**, v.19, n.3, 2015a.

CALDEIRA, T. L.; BESKOW, S.; MELLO, C. R.; VARGAS, M. M.; GUEDES, H. A. S.; FARIA, L. C. Desagregação de chuva diária: uma análise para o estado do Rio Grande do Sul. **Scientia Agraria**, v.16, n.3, 2015b.

CECÍLIO, R. A.; PRUSKI, F. F. Interpolação dos parâmetros de equações de chuvas intensas com uso do inverso de potências da distância. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.7, n.3, p.501-504, 2003.

CETESB - Companhia de Tecnologia de Saneamento Ambiental. **Drenagem urbana: manual de projeto**. 1ed. São Paulo: DAEE/CETESB, 1986, 466p.

CHEN, C. Rainfall Intensity - duration – frequency formulas. **Journal of Hydraulic Engineering**, ASCE, v.109, n.12, p.1603-21. 1983.

CHEN, M.; SHI, W.; XIE, P.; SILVA, V. B. S.; KOUSKY, V. E.; HIGGINS, R. W.; JANOWIAK, J. E. Assessing objective techniques for gauge-based analyses of global daily precipitation. **Journal of Geophysical Research Atmospheres**, v.113, p.1-13, 2008. Disponível em: <https://doi.org/10.1029/2007JD009132>.

CHIEW, F.; SIRIWARDENA, L. Trend user guide. Australia: CRC for catchment hydrology. 2005. 29 p. Disponível em: <https://toolkit.ewater.org.au/Tools/DownloadDocumentation.aspx?id=1000353>.

CHOO, Y.M.; JO, D.J.; YUN, G.S.; LEE, E.H. A study on the improvements of flood forecasting techniques in urban areas by considering rainfall intensity and duration. **Water**, v.11, n.1883, 2019.

CLARKE, R. T. Hydrological prediction in a non-stationary world. **Hydrology and Earth System Sciences**, v.11, p.408-414, 2007.

COLES, S. **An introduction to statistical modeling of extreme values**. Springer Series in Statistics. Springer-Verlag, London, 2001.

COLLISCHONN, W.; DORNELLES, F. **Hidrologia para engenharia e ciências ambientais**. 2 ed. Porto Alegre: Associação Brasileira de Recursos Hídricos (ABRH), 2015. 336p. (Coleção ABRH, 12).

COSTA, J.; PEREIRA, G., SIQUEIRA, M. L.; CARDOZO, F. Validação dos dados de precipitação estimados pelo CHIRPS para o Brasil. **Revista Brasileira de Climatologia**, ano 15, v.24, p.228-243, 2019.

COSTA, F.; RUFINO, I. A. A.; ARAGÃO, R. de; FILHO, R. da S. R. Performance evaluation of four remote-sensing products throughout precipitation estimation in the State of Paraíba, Northeast Brazil. **Remote Sensing Applications: Society and Environment**, v. 35, 2024. Disponível em: <https://doi.org/10.1016/j.rsase.2024.101256>.

CROSS, R. **World disasters report (2010) focus on urban risk**. International Federation of Red Cross and Red Crescent Societies, Geneva, 2010.

CUNHA, Z.; VARGAS, M.; MOURA, M.; CALDEIRA, T.; BESKOW, S. Propostas baseadas em algoritmos genéticos para otimização de parâmetros de curvas intensidade-duração-frequência (IDF). In: **XXII Encontro de Pós-Graduação - UFPel**, 2019, Pelotas. Anais. Pelotas: UFPel, 2019.

DINIS, P.A.; HUVI, J.; CABRAL PINTO, M.; CARVALHO, J. Disastrous flash floods triggered by moderate to minor rainfall events. Recent Cases in Coastal Benguela (Angola). **Hydrology**, v.8, n.2, 2021. Disponível em: <https://doi.org/10.3390/hydrology8020073>.

DINKU, T.; CHIDZAMBWA, S.; CECCATO, P.; CONNOR, S. J.; ROPELEWSKI, C. F. Validation of high-resolution satellite rainfall products over complex terrain. **International Journal of Remote Sensing**, v.29, n.14, p.4097–4110, 2008. Disponível em: <https://doi.org/10.1080/01431160701772526>.

DORNELES, V. R.; DAMÉ, R. de C. F.; MÉLLO, C. F. A.; TEIXEIRA-GANDRA, C. F. A.; RAMIREZ, M. A. A.; MANKE, E. B. Intensity-duration-frequency relationships of rainfall through the technique of disaggregation of daily rainfall. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 23, n. 7, p. 506–510, 2019. Disponível em: <https://doi.org/10.1590/1807-1929/agriambi.v23n7p506-510>.

DUAN, Q.; SOROOSHIAN, S.; GUPTA, V. K. Effective and efficient global optimization for conceptual rainfall-runoff models. **Water Resources Research**, v.28, n.4, p.1015–1031, 1992.

DUAN, Z. 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. Disponível em: <https://doi.org/10.1016/j.scitotenv.2016.08.213>.

ENFIELD, D. B.; MESTAS-NUNEZ, A. M.; TRIMBLE, P. J. The Atlantic Multidecadal Oscillation and its relation to rainfall and river flows in the continental U.S. **Geophys.**

**Res. Lett.**, v.28, n.10, p.2077–2080, 2001. Disponível em: <https://doi.org/10.1029/2000GL012745>.

FAGUNDES, F.; SILVA, J.; SCHMITT, E.; ZUKOWSKI JUNIOR, J. Aplicação da equação de intensidade pluviométrica do município de Gurupi – Tocantins. **Revista AIDIS de Ingeniería y Ciencias Ambientales**, v.13, n.2, p.443-455, 2020. Disponível em: <https://doi.org/10.22201/iingen.0718378xe.2020.13.2.65572>

FENDRICH, R. **Chuvas intensas para obras de drenagem no Estado do Paraná**. Curitiba: Champangnat, 1998. 99p.

FERRAZ, L.L.; NEVES, J.R.D.; GONÇALVES, L.J.; SOUSA, L.F.; OLIVEIRA, L.B. Determinação da equação intensidade-duração-frequência da precipitação para a cidade de Itabuna, Bahia (Brasil). **Revista Brasileira de Meio Ambiente**, v.8, n.2, p. 087-098, 2020a.

FERRAZ, L.L.; SILVA, L.S.; SOUSA, L.F.; SANTOS, C.A.S.; NEVES, J.R.D. Equações de chuvas intensas para a bacia hidrográfica do rio Cachoeira – Sul do Estado da Bahia - Brasil. **Enciclopédia Biosfera**: Jandaia-GO, v.17, n.33, p. 194, 2020b.

FERREIRA, P.S.; GOMES, V.P.; GALVÍNIO, J.D.; SANTOS, A.M.; SOUZA, W.S. Avaliação da tendência espaço-temporal da precipitação pluviométrica em uma região semiárida do estado de Pernambuco. **Revista Brasileira de Climatologia**, ano 13, v.21, pp.113-134, 2017.

FIORIO, P.; DUARTE, S.; RODRIGUES, G.; MIRANDA, J.; COOKE, R. Comparação de equações de chuvas intensas para localidades do estado de São Paulo. **Eng. Agric.**, v.32, n.6, p.1008-1088, 2012.

FRANKS, S. W.; KUCZERA, G. Flood frequency analysis: Evidence and implications of secular climate variability, New South Wales. **Water Resour. Res.**, v.38, n.5, p.20-1–20-7, 2002. Disponível em: <https://doi.org/10.1029/2001WR000232>.

FREITAS, A. J.; SILVA, D. D.; PRUSKI, F. F.; PINTO, F. A.; PEREIRA, S. B.; GOMES FILHO, R. R.; TEIXEIRA, A. F.; BAENA, L. G. N.; MELLO, L. T. A.; NOVAES, L. F. **Equações de chuvas intensas no Estado de Minas Gerais**. Belo Horizonte, Companhia de Saneamento de Minas Gerais/Universidade Federal de Viçosa, 2001. 65p.

FREITAS, E. da S.; COELHO, V. H. R.; XUAN, Y.; MELO, D. de C. D.; GADELHA, A. N.; SANTOS, E. A.; GALVÃO, C. de O.; RAMOS FILHO, G. M.; BARBOSA, L. R.; HUFFMAN, G. J.; PETERSEN, W. A.; ALMEIDA, C. das N. The performance of the IMERG satellite-based product in identifying sub-daily rainfall events and their properties. **Journal of Hydrology**, v. 589, 2020. Disponível em: <https://doi.org/10.1016/j.jhydrol.2020.125128>.

FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; SHUKLA, S.; HUSAK, G.; ROWLAND, J.; HARRISON, L.; HOELL, A.; MICHAELSEN, J. The climate hazards infrared precipitation with stations - a new environmental record for monitoring extremes. **Sci data**, v.2, p.1–21, 2015. Disponível em: <https://doi.org/10.1038/sdata.2015.66>.

G1 BAHIA, G. **Ponte é liberada para veículos, cerca de 20 dias após enchente de rio em Itabuna.** Disponível em: <https://g1.globo.com/ba/bahia/noticia/2022/01/10/ponte-segue-interditada-para-veiculos-cerca-de-20-dias-apos-enchente-de-rio-em-itabuna.ghtml>. Acesso em: 29 abr. 2022a.

G1 BAHIA, G.; TV BAHIA, T. **Após Rio Cachoeira subir 9 metros, nível da água começa a baixar e moradores contabilizam prejuízos em Itabuna.** Disponível em: <https://g1.globo.com/ba/bahia/noticia/2021/12/27/apos-rio-cachoeira-subir-9-metros-nivel-da-agua-comeca-a-baixar-e-moradores-contabilizam-prejuizos-em-itabuna.ghtml>. Acesso em: 29 abr. 2022b.

G1 BAHIA, G; TV SANTA CRUZ. **Temporal que causou inundações em cidades do sul da BA completa um ano e moradores relatam medo de novos alagamentos.** 2022. Disponível em: <https://g1.globo.com/ba/bahia/noticia/2022/12/14/temporal-que-causou-inundacoes-em-cidades-do-sul-da-ba-completa-um-ano.ghtml>. Acesso em: 15 mai. 2024.

G1-GLOBO. **Ondas de calor - atuação de um bloqueio atmosférico, refletindo em dias ensolarados com temperaturas elevadas, provocando elevadas ondas de calor e precipitação torrencial.** Disponível em <https://g1.globo.com/ba/bahia/noticia/2023/04/21/meteorologista-explica-onda-de-calor-e-virada-no-tempo-na-bahia.ghtml>. Acesso em 07 mai. 2023.

GALAVI, H.; MIRZAEI, M. Analyzing uncertainty drivers of climate change impact studies in tropical and arid climates. **Water Resources Management**, v.34, n.6, p.2097–2109, 2020.

GALAVI, H.; KAMAL, M. R.; MIRZAEI, M.; EBRAHIMIAN, M. Assessing the contribution of different uncertainty sources in streamflow projections. **Theoretical and Applied Climatology**, v.137 (1–2), p.1289–1303, 2019.

GAO, F.; ZHANG, Y.; CHEN, Q.; WANG, P.; YANG, H.; YAO, Y.; CAI, W. Comparison of two long-term and high-resolution satellite precipitation datasets in Xinjiang, China. *Atmospheric Research*, v. 212, 2018, p. 150-157, 8095, Disponível em: <https://doi.org/10.1016/j.atmosres.2018.05.016>.

GARCEZ, L. N.; ALVAREZ, G. A. **Hidrologia**. 2 ed. Edição revisada e atualizada - São Paulo: Blucher, 1988. 291p.

GARCIA, S. S.; AMORIM, R. S. S.; COUTO, E. G.; STOPA, W. H. Determinação da equação intensidade-duração-frequência para três estações meteorológicas do Estado de Mato Grosso. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.15, n.6, p.575-581, 2011.

GASH, J. H. C.; NOBRE, C. A. Climatic effects of Amazonian deforestation: Some results from ABRACOS. **Bull. Am. Meteorol. Soc.**, v.78, n.5, p.823–830, 1997.

GHANMI, H.; BARGAOUI, Z.; MALLET, C. Estimation of intensity-duration-frequency relationships according to the property of scale invariance and regionalization analysis in a Mediterranean coastal area. **Journal of Hydrology**, v.541, p.38–49, 2016. Disponível em: <https://doi.org/10.1016/j.jhydrol.2016.07.002>.

GNECCO, I.; PALLA, A.; LA BARBERA, P.; ROTH, G.; GIANNONI, F. Defining intensity-duration-frequency curves at short durations: a methodological framework. **Hydrological Sciences Journal**, 2023.

GOULART, J. P.; MAESTRINI, A. P.; NEBEL, A. L. Relação Intensidade-Duração-Frequência das Chuvas em Pelotas, RS. **Revista Brasileira de Meteorologia**, v.7, n.1, p.543-552, 1992.

GPRH (Grupo de Pesquisas em Recursos Hídricos). **Plúvio 2.1**, 2006. Departamento de Engenharia Agrícola da Universidade Federal de Viçosa. Disponível em: <<http://www.gprh.ufv.br/?area=softwares>>.

HEJAZI, M. I.; MARKUS, M. Impacts of urbanization and climate variability on floods in northeastern Illinois. **J. Hydrol. Eng.**, v.14, n.6, 2009. Disponível em: [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000020](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000020).

HIPEL, K. W.; McLEOD, A. I. Times series modelling of water resources and environmental systems. **Elsevier**, Amsterdam, 1054 f, 1994.

HONG, Y.; GOCHIS, D.; CHENG, J.; HSU, K.; SOROOSHIAN, S. Evaluation of PERSIANNCCS rainfall measurement using the NAME event rain Gauge Network. **J. Hydrometeorol.** V.8, n.3, p.469–482, 2007. Disponível em: <https://doi.org/10.1175/JHM574.1>.

HOSKING, J. R. M.; WALLIS, J. R. **Regional frequency analysis: An approach based on L-moments**. Cambridge, England: Cambridge University Press, 244 p., 1997.

HOSKING, J. R. M.; WALLIS, J. R. Package 'lmom': L-Moments, 2024.

HOSSEINZADEHTALAEI, P.; TABARI, H.; WILLEMS, P. Climate change impact on short-duration extreme precipitation and intensity-duration-frequency curves over Europe. **Journal of Hydrology**, v.590, 2020.

HSU, K.-L.; GAO, X.; SOROOSHIAN, S.; GUPTA, H.V. Precipitation estimation from remotely sensed information using artificial neural networks. **J. Appl. Meteorol.**, v.36, n.9 p.1176–1190, 1997. Disponível em: [https://doi.org/10.1175/1520-0450\(1997\)036<1176:PEFRSI>2.0.CO;2](https://doi.org/10.1175/1520-0450(1997)036<1176:PEFRSI>2.0.CO;2).

HUFFMAN, G.J.; ADLER, R.F.; BOLVIN, D.T.; GU, G.J.; NELKIN, E.J.; BOWMAN, K.P.; HONG, Y.; STOCKER, E.F.; WOLFF, D.B. The TRMM multisatellite precipitation analysis (TMPA): quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. **J. Hydrometeorol.**, v.8, n.1, p.38–55, 2006. Disponível em: <https://doi.org/10.1175/JHM560.1>.

HUFFMAN, G.J.; BOLVIN, D.T.; BRAITHWAITE, D.; HSU, K.L.; JOYCE, R.; KIDD, C.; NELKIN, E.J.; SOROOSHIAN, S.; TAN, J.; XIE, P. Algorithm Theoretical Basis Document (ATBD) Version 06 NASA Global Precipitation Measurement (GPM) Integrated multi-satellite Retrievals for GPM (IMERG). **Natl Aeronaut Sp Adm**, p.1-34, 2019.

IBGE (Instituto Brasileiro de Geografia e Estatística). Estimativa da população. 2024. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/populacao/9103-estimativas-de-populacao.html>. Acesso em: 29 nov. 2024.

IPCC (Intergovernmental Panel on Climate Change). *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Edited by VALERIU, Masson-Delmotte et al. Cambridge: Cambridge University Press, 2021. Disponível em: <https://www.ipcc.ch/report/ar6/wg1/>. Acesso em: 29 nov. 2024.

KANG, N.; KIM, S.; KIM, Y.; NOH, H.; HONG, S.; KIM, H. Urban Drainage System Improvement for Climate Change Adaptation. **Journal of Water**, v.8, n.7, p.268, 2016.

KASI, V.; PINNINTI, R.; LANDA, S.R.; RATHINASAMY, M.; SANGAMREDDI, C.; KUPPILI, R.R.; RADHA, P.R.D. Comparison of different digital elevation models for drainage morphometric parameters: a case study from South India. **Arab J Geosci**, v.13, p.1–17, 2020. <https://doi.org/10.1007/s12517-020-06049-4>.

KATZ R.W.; PARLANGE M.B.; NAVEAU P. Statistics of extremes in hydrology. **Advances in Water Resources**, v.25, p.1287–1304, 2002.

KENDALL, M. G., Rank Correlation Methods, 4th ed., Charles Griffin: London, 1975.

KIEM, A. S.; FRANKS, S. W.; KUCZERA, G. Multi-decadal variability of flood risk. **Geophys. Res. Lett.**, v.30, n.2, 2003. Disponível em: <https://doi.org/10.1029/2002GL015992>.

KIM, H.; KIM, S.; SHIN, H.; HEO, J. H. Appropriate model selection methods for nonstationary generalized extreme value models. **Journal of Hydrology**, v. 547, p. 557-574, 2017. Disponível em: <https://doi.org/10.1016/j.jhydrol.2017.02.005>.

KUMAR, Y.P.; MAHESWARAN, R.; AGARWAL, A.; SIVAKUMAR, B. Intercomparison of downscaling methods for daily precipitation with emphasis on wavelet-based hybrid models. **J Hydrol**, v.599, 2021. Disponível em: <https://doi.org/10.1016/j.jhydrol.2021.126373>

KOUTSOYIANNIS, D.; KOZONIS, D.; MANETAS, A. A mathematical framework for studying rainfall intensity-duration-frequency relationships. **Journal of Hydrology**, v.206, p.118-135, 1998.

LEWIS, E.; FOWLER, H.; ALEXANDER, L.; DUNN, R.; MCCLEAN, F.; BARBERO, R.; GUERREIRO, S.; LI, X.; BLENKINSOP, S. GSDR: a global sub-daily rainfall dataset. **Journal of Climate**, v.32, n.15, p.4715-4729, 2019. Disponível em: <http://dx.doi.org/10.1175/jcli-d-18-0143.1>.

LIMA NETO, V. de S.; TAVARES, P. R. L.; BATISTA, T. L. Adjustment and validation of IDF equations from pluviometric data for cities in the state of Pernambuco, Brazil. **Revista Brasileira de Meteorologia**, v. 36, n. 4, p. 713–721, 2021. Disponível em: <https://doi.org/10.1590/0102-7786360031>.

LIU, Chian-Yi. ARYASTANA, Putu. LIU, Gin-Rong. HUANG, Wan-Ru. Assessment of satellite precipitation product estimates over Bali Island. **Atmospheric Research**, v. 244, 2020. Disponível em: <https://doi.org/10.1016/j.atmosres.2020.105032>.

LIU, Jun. SHANGGUAN, Donghui. LIU, Shiyin. DING, Yongjian. WANG, Shaoping. WANG, Xiuna. Evaluation and comparison of CHIRPS and MSWEP daily-precipitation products in the Qinghai-Tibet Plateau during the period of 1981–2015. **Atmospheric**

**Research**, v.230, 2019, Disponível em:  
<https://doi.org/10.1016/j.atmosres.2019.104634>.

LLAUCA, H.; LAVADO-CASIMIRO, W.; LEÓN, K.; JIMENEZ, J.; TRAVERSO, K.; RAU, P. Assessing near real-time satellite precipitation products for flood simulations at sub-daily scales in a sparsely gauged watershed in Peruvian Andes. **Remote Sensing**, v.13, n.4, p.826, 2021. Disponível em: <http://dx.doi.org/10.3390/rs13040826>.

LÓPEZ-BERMEO, C.; MONTOYA, R. D.; CARO-LOPERA, F. J.; DÍAZ-GARCÍA, J. A. Validation of the accuracy of the CHIRPS precipitation dataset at representing climate variability in a tropical mountainous region of South America. **Physics and Chemistry of the Earth**, v.127, 2022. Disponível em: <https://doi.org/10.1016/j.pce.2022.103184>.

MAITY, S.; MAITY, R. Changing pattern of intensity-duration-frequency relationship of precipitation due to climate change. **Water Resources Management**, v.36, n. 14, p.5371-5399, 2022.

MANN, H. B., Non-parametric test against trend. **Econometrica**, v.13, p.245-259, 1945.

MARENGO, J.A.; VALVERDE, R.; OBREGON, G.O. Observed and projected changes in rainfall extremes in the Metropolitan Area of São Paulo. **Climate Research**, v.57, n.1, p.61-72, 2013. Disponível em:  
<https://www.researchgate.net/publication/260057016>.

MATOS, J.E.R. **Chuvas intensas no Estado da Bahia**: equações e metodologias de regionalização. Salvador: EDUFBA, 2006. 296p.

MCCABE, G. J.; WOLOCK, D. M. A step increase in streamflow in the conterminous United States. **Geophys. Res. Lett.**, v.29, n.24, p.31-1-38-4, 2002. Disponível em:  
<https://doi.org/10.1029/2002GL015999>.

MELLO, C. R.; SILVA, A. M. **Hidrologia**: princípios e aplicações em sistemas agrícolas. Lavras: Ed. UFLA, 2013. 455p.

MELLO, C. R.; VIOLA, M. R; MELLO, J. M; SILVA, A. M. Spatial continuity of intense rainfall in Minas Gerais State, Brazil. **Ciência e Agrotecnologia**, v.32, n.2, p.532-539, 2008.

MIANABADI, A. Evaluation of long-term satellite-based precipitation products for developing intensity-frequency (IF) curves of daily precipitation. **Atmospheric Research**, v.286, 2023.

MILLY, P. C. D.; BETANCOURT, J.; FALKENMARK, M.; HIRSCH, R. M.; KUNDZEWICZ, Z. W.; LETTENMAIER, D. P.; STOUFER, R. J. Stationarity is dead: Whiter water management? **Science**, v.319, p.573–574, 2008.

MIN, X.; YANG, C.; DONG, N. Merging satellite and gauge rainfalls for flood forecasting of two catchments under different climate conditions. **Water**, v.12, n.3, p.802, 2020. Disponível em: <http://dx.doi.org/10.3390/w12030802>.

MORAES, J.M.; GENOVEZ, A.M.; MORTATTI, J.; BALLESTER, M.V.; KRUSCH, A.V., MARTINELLI, L.A.; VICTORIA, R.L. Análise de intervenção das séries temporais de

vazão dos principais rios da bacia do Rio Piracicaba. **Revista Brasileira de Recursos Hídricos**, v.2, n.2, p.65-79, 1997.

MOREIRA, J. G. do V.; NAGHETTINI, M.; ELEUTÉRIO, J.C. Frequência e risco sob não-estacionariedade em registros pluviométricos da bacia do alto rio Tarauacá, Acre. **Revista Brasileira de Recursos Hídricos**, v.21, n.1, p.232-241, 2016.

MOURA, A. R. **Critérios de seleção de modelos: um estudo comparativo**. Dissertação de Mestrado (Modelagem Matemática e Computacional) – Universidade Federal da Paraíba, João Pessoa, 2021, 96p.

NAGHETTINI, M.; PINTO, É. **Hidrologia Estatística**. CPRM, Belo Horizonte, 552 p, 2007.

NASCIMENTO, Y.; JESUS, J. Relações intensidade-duração-frequência de precipitações para o município de Tucano, Bahia. *Agropecuária Científica no Semiárido*, v.13, n.4, p.302-306, 2017.

NATIVIDADE, U.A.; GARCIA, S.R.; TORRES, R.R. Tendência dos índices de extremos climáticos observados e projetados no Estado de Minas Gerais. **Revista Brasileira de Meteorologia**, v.32, n.4, p.600-614, 2017.

NGUYEN, P.; THORSTENSEN, A.; SOROOSHIAN, S.; HSU, K.; AGHAKOUCHAK, A.; ASHOURI, H.; TRAN, H.; BRAITHWAITE, D. Global precipitation trends across spatial scales using satellite observations. **Bull. Am. Meteorol. Soc.**, v.99, n.4, p.689-697, 2018. Disponível em: <https://doi.org/10.1175/BAMS-D-17-0065.1>.

NGUYEN, P.; OMBADI, M.; GOROOSH, V.A.; SHEARER, E.; SADEGHI, M.; SOROOSHIAN, S.; HSU, K.; BOLVIN, K.; RALPH, M.F. PERSIANN Dynamic Infrared-Rain Rate (PDIR-Now): A Near-Real-Time, Quasi-Global Satellite Precipitation Dataset. **J Hydrometeorol**, v.21, n.12, p.2893-2906, 2020. Disponível em: <https://doi.org/10.1175/jhm-d-20-0177.1>.

NOOR, M.; ISMAIL, T.; CHUNG, E. S.; SHAHID, S.; SUNG, J. H. Uncertainty in rainfall intensity duration frequency curves of Peninsular Malaysia under changing climate scenarios. **Water (Switzerland)**, v. 10, n. 12, 2018. Disponível em: <https://doi.org/10.3390/w10121750>.

NOOR, M.; ISMAIL, T.; SHAHID, S.; ASADUZZAMAN, M.; DEWAN, A. Evaluating intensity-duration-frequency (IDF) curves of satellite-based precipitation datasets in Peninsular Malaysia. **Atmospheric Research**, v. 248, 2021. Disponível em: <https://doi.org/10.1016/j.atmosres.2020.105203>.

NORBIATO, D.; BORGA, M.; ESPOSTI, S.D.; GAUME, E.; ANQUETIN, S. Flash Flood warning based on rainfall thresholds and soil moisture conditions: An assessment for gauged and ungauged basins. **Journal of Hydrology**, v.362, p.274-290, 2008.

NUNES, A. A. Tendências em eventos extremos de precipitação na região metropolitana de Belo Horizonte: detecção, impactos e adaptabilidade. Tese de Doutorado (Saneamento, Meio Ambiente e Recursos Hídricos) – Universidade Federal de Minas Gerais, Belo Horizonte/MG, 2018.

NUNES, A. A.; PINTO, E. J. A.; BAPTISTA, M. B.; de PAULA, M. H.; XAVIER, M. O. Intensity-duration-frequency curves in the municipality of Belo Horizonte from the

perspective of non-stationarity. **Revista Brasileira de Recursos Hídricos**, v.26, e.29, 2021. Disponível em: <https://doi.org/10.1590/2318-0331.262120210017>.

OBEYSEKERA, J.; SALAS, J. D. Quantifying the uncertainty of design floods under nonstationary conditions. **Journal of Hydrologic Engineering**, v.19, n.3, p.1438-1446, 2014.

OLIVEIRA, L. F. C.; CORTÊS, F. C.; WEHR, T. R.; BORGES, L. B.; SARMENTO, P. H. L.; GRIEBELER, N. P. Intensidade-Duração-Frequência de chuvas intensas para localidades no estado de Goiás e Distrito Federal. **Pesquisa Agropecuária Tropical**, v.35, n.1, p.13-18, 2005.

OLIVEIRA, L. F. C.; ANTONINI, J. C. A.; GRIEBELER, N. P. Estimativas de chuvas intensas para o Estado de Goiás. **Engenharia Agrícola**, v.28, n.1, p.22-33, 2008.

OMBADI, M.; NGUYEN, P.; SOROOSHIAN, S.; HSU, K. Developing Intensity-Duration-Frequency (IDF) curves from satellite-based precipitation: methodology and evaluation. **Water Resour**, v. 54, p.7752–7766, 2018. Disponível em: <https://doi.org/10.1029/2018WR022929>.

PAREDES-TREJO, F.J.; BARBOSA, H.A.; KUMAR, T.V. Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil. **Journal of Arid Environments**, v.139, p.26-40, 2017. Disponível em: <https://doi.org/10.1016/j.jaridenv.2016.12.009>.

PARK, J.; OBEYSEKERA, J.; BARNES, J.; IRIZARRY, M.; PARK-SAID, W. Climate links and variability of extreme sea level events at Key West, Pensacola, and Mayport Florida. **J. Waterway, Port, Coastal, Ocean Eng.**, v.136, n.6, p.350–356, 2010.

PARK, J.; OBEYSEKERA, J.; IRIZARRY, M.; BARNES, J.; TRIMBLE, P.; PARK-SAID, W. Storm surge projections and implications for water management in south Florida. **Clim. Change**, v.107, n.1–2, p.109–128, 2011. Disponível em: <https://link.springer.com/article/10.1007/s10584-011-0079-8>.

PARVIN, G. A.; SHIMI, A. C.; SHAW, R.; BISWAS, C. Flood in a changing climate: The impact on livelihood and how the rural poor cope in Bangladesh. **Climate**, v. 4, n. 4, 2016. Disponível em: <https://doi.org/10.3390/cli4040060>.

PFAFSTETTER, O. **Chuvas intensas no Brasil: Relação entre precipitação, duração e frequência em 98 postos com pluviógrafos**. 1ed. Rio de Janeiro: DNOS - Departamento Nacional de Obras e Saneamento do Ministério da Viação e Obras Públicas, 1957. 419P.

PIELKE Sr, R. A.; ADEGOKE, J.; BELTRÁN-PRZEKURAT, A.; HIEMSTRA, C. A.; LIN, J.; NAIR, U. S.; NIYOGI, D.; NOBIS, T. E. An overview of regional land-use and land-cover impacts on rainfall. **Tellus B**, v.59, n.3, p.587–601, 2007. Disponível em: <https://doi.org/10.1111/j.1600-0889.2007.00251.x>.

PINTO, F. A. **Chuvas intensas no Estado de Minas Gerais: análises e modelos**. Tese de Doutorado (Engenharia Agrícola) – Universidade Federal de Viçosa, Viçosa/MG, 1995. 87p.

PRAKASH, S.; MITRA, A.K.; PAI, D.S.; AGHAKOUCHAK, A. From TRMM to GPM: how well can heavy rainfall be detected from space? **Adv. Water Resour**, v.88, p.1–7, 2016. Disponível em: <https://doi.org/10.1016/j.advwatres.2015.11.008>.

PRESOTTO, M.A. **Determinação de coeficientes de desagregação e relações IDF para o estado do Rio Grande do Sul por meio de séries de duração parcial.** Dissertação de Mestrado (Engenharia Civil) – Universidade Federal de Santa Maria, Santa Maria, RS, 2020. 100p.

QUEIROZ, M.A. Avaliação de tendências em séries de precipitação diária máxima anual na faixa central do estado de Minas Gerais. Belo Horizonte: UFMG.184p. Dissertação de Mestrado, 2013.

RAMOS FILHO, G. M.; COELHO, V. H. R.; FREITAS, E. da S.; XUAN, Y.; BROCCA, L.; ALMEIDA, C. das N. Regional-scale evaluation of 14 satellite-based precipitation products in characterising extreme events and delineating rainfall thresholds for flood hazards. **Atmospheric Research**, v. 276, 2022. Disponível em: <https://doi.org/10.1016/j.atmosres.2022.106259>.

RANGEL, M. C. **A crise do território-região cacauieira da Bahia: os nós discursivos nas tramas do poder local para manter o território - 1980-2010.** Tese de doutorado - Universidade Estadual de Maringá, Maringá-PR, 2013. Disponível em: <http://www.pge.uem.br/documentos-para-publicacao/teses/teses-2013-pdfs/MariaCristinaRangelTeseFinal.pdf>.

RAUF, A.; GHUMMAN, A.R. Impact assessment of rainfall-runoff simulations on the flow duration curve of the Upper Indus River-a comparison of data-driven and hydrologic models. **Water**, v.10, n.7, p.876, 2018. Disponível em: <https://doi.org/10.3390/w10070876>.

RIBEIRO M.E.; BORTOLIN, T.A.; MENDES, L.A. Análise da estacionariedade e homogeneidade de séries hidrológicas na bacia de contribuição da UHE Castro Alves, RS. *In: XXIII Simpósio Brasileiro de Recursos Hídricos, 2019, Foz do Iguaçu-PR. Anais eletrônicos.* Foz do Iguaçu: ABRHidro, 2019. Disponível em: <https://anais.abrhidro.org.br/job.php?Job=5798>.

ROOTZÉN, H.; KATZ, R. W. Design life level: Quantifying risk in a changing climate. **Water Resources Research**, v.49, n.9, p.5964-5972, 2013. Disponível em: <https://doi.org/10.1002/wrcr.20425>.

SABATER, J. M. ERA5-Land hourly data from 1981 to present. **Climate Data Store (CDS)**, 2019. Disponível em: <http://dx.doi.org/10.24381/cds.e2161bac>.

SABINO, M.; SOUZA, A.; ULIANA, E.; LISBOA, L.; ALMEIDA, F.; ZOLIN, C. Intensity-duration-frequency of maximum rainfall in Mato Grosso State. **Revista Ambiente e Água**, v. 15, n. 1, 2020. Disponível em: <https://doi.org/10.4136/1980-993X>.

SADEGHI, M.; NGUYEN, P.; NAEINI, M.R.; HSU, K.; BRAITHWAITE, D.; SOROOSHIAN, S. PERSIANN-CCS-CDR, a 3-hourly 0.04° global precipitation climate data record for heavy precipitation studies. **Sci. Data**, v.8, n.157, 2021. Disponível em: <https://doi.org/10.1038/s41597-021-00940-9>.

SALAS, J. D.; OBEYSEKERA, J. Revisiting the concepts of return period and risk for nonstationary hydrologic extreme events. *J. Hydrol. Eng.*, v.19, n.3, p.554-568, 2014. Disponível em: <https://ascelibrary.org/doi/10.1061/%28ASCE%29HE.1943-5584.0000820>.

SCHARDONG, A.; SRIVASTAV, R.; SIMONOVIC, S. Atualização da equação intensidade-duração-frequência para a cidade de São Paulo sob efeito de mudanças climáticas. **RBRH**, v.19, n.4, p.176-185, 2014.

SCHILLING, K. E.; LIBRA, R. D. Increased baseflow in Iowa over the second half of the 20th century. **J. Am. Water Resour. Assoc.**, v.39, n.4, p.851–860, 2007. Disponível em: <https://doi.org/10.1111/j.1752-1688.2003.tb04410.x>.

SILVA, D. D., GOMES FILHO, R. R. G., PRUSKI, F. F., PEREIRA, S. B., NOVAIS, L. F. Chuvas intensas do Estado da Bahia. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande-PB, v. 6, n. 2, p. 362-367, 2002.

SILVA, D. D.; PEREIRA, S. B.; PRUSKI, F. F.; GOMES FILHO, R. R.; LANA, A. M. Q.; BAENA, L. G. N. Equações de intensidade-duração-frequência da precipitação pluvial para o estado de Tocantins. **Engenharia na Agricultura**, v.11, n.31, p.7-14, 2003.

SILVA, E. R. M.; BARBOSA, I.C.C.; SILVA, H. J. F.; COSTA, L. G. S.; ROCHA, E. J. P. Análise do desempenho da estimativa de precipitação do produto CHIRPS para sub-bacia do Rio Apeú, Castanhal-PA. **Revista Brasileira de Geografia Física**, v.13, n.3, p.1094-1105, 2020.

SOARES, A. S. D.; DA PAZ, A. R.; PICCILLI, D. G. A. Avaliação das estimativas de chuva do satélite TRMM no Estado da Paraíba. **Revista Brasileira de Recursos Hídricos**, v. 21, n. 2, p. 288–299, 2016. Disponível em: <https://doi.org/10.21168/rbrh.v21n2.p288-299>.

SOUZA, G. R.; BELLO, I. P.; OLIVEIRA, L. F. C.; CORREA, F. V. Mapas de chuvas intensas no Brasil com tempo de retorno de 5 anos. **Ambiente e Água**, v.14, n.5, 2019. Disponível em: <https://doi.org/10.4136/ambi-agua.2403>.

SUN, Q.; ZHANG, X.; ZWIERS, F.; WESTRA, S.; ALEXANDER, L. V. A global, continental, and regional analysis of changes in extreme precipitation. **Journal of Climate**, v.34, n.1, p.243–258, 2021. Disponível em: [10.1175/jcli-d-19-0892.1](https://doi.org/10.1175/jcli-d-19-0892.1).

SUZUKI, Y.; NAKAMURA, K.; HAMA, T. Peak discharge mitigation effects in different rainfall patterns at a paddy plot with a runoff control plate. **Journal of Hydrology: Regional Studies**, v. 42, 2022. Disponível em: <https://doi.org/10.1016/j.ejrh.2022.101165>.

TABARI, H. Extreme value analysis dilemma for climate change impact assessment on global flood and extreme precipitation. **Journal of Hydrology**, v.593, 2021. Disponível em: [10.1016/j.jhydrol.2020.125932](https://doi.org/10.1016/j.jhydrol.2020.125932).

TAVARES, P. S.; PILOTTO, I. L.; CHOU, S. C.; SOUZA, S. A., FONSECA, L. M. G. Projeções climáticas para América do Sul regionalizadas pelo modelo Eta com correção de viés. **LattesData**, v. 01, 2023. Disponível em: <https://lattesdata.cnpq.br/dataset.xhtml?persistentId=doi:10.57810/lattesdata/WAVGSL>.

TOFFOL, S; LAGHARI, A. N.; RAUCH, W. Are extreme rainfall intensities more frequent? Analysis of trends in rainfall patterns relevant to urban drainage systems. **Water Science & Technology**, v.59, n.9, p.1769-1776, 2009.

TRANG, H. T.; MANOMAIPHIBOON, K.; SINGHRATTNA, N.; ASSAREH, N. Evaluation of multiple sub-daily satellite precipitation products for Thailand. **Journal of Sustainable Energy and Environment**, v. 11, p. 81–91, 2020. Disponível em: [http://www.tmd.go.th/met\\_dict.php](http://www.tmd.go.th/met_dict.php).

TUCCI, C. E. M. **Hidrologia: Ciência e Aplicação**. 4. ed. Porto Alegre: UFRGS, 2009. 943p.

UNITED NATIONS. **The Human Cost of Weather-Related Disasters: 1995–2015**. United Nations Office for Disaster Risk Reduction: Genève, Switzerland, 2015.

VALVERDE, M. C.; CARDOSO, A. de O.; BRAMBILA, R. O padrão de chuvas na região do ABC Paulista: Os extremos e seus impactos. **Revista Brasileira de Climatologia**, ano 14, v.22, p.165-187, 2018.

VARGAS, M. M.; BESKOW, S.; CALDEIRA, T. L.; MELLO, C. R.; FARIA, L. C.; GUEDES, H. A. S.; CUNHA, Z. A.; MINKS, D. N.; KERSTNER, L.; MORTEO, D. S. R.; ROSA, E. M.; LUZ, E. P. Análise de constantes de desagregação de chuva diária no estado do Rio Grande do Sul. *In: XXI Simpósio Brasileiro de Recursos Hídricos*, 2015, Brasília. **Anais eletrônicos**. Brasília: ABRHidro, 2015. Disponível em: <https://anais.abrhidro.org.br/job.php?Job=8520>.

VARGAS, M.; MOURA, M.; CUNHA, Z.; BESKOW, S.; CALDEIRA, T. Alternativas computacionais para otimização dos parâmetros da IDF: abordagem inicial. *In: XXIII Simpósio Brasileiro de Recursos Hídricos*, 2019, Foz do Iguaçu. Anais. Porto Alegre: ABRHidro, 2019.

VENKATESH, K.; MAHESWARAN, R.; DEVACHARAN, J. Framework for developing IDF curves using satellite precipitation: a case study using GPM-IMERG V6 data. **Earth Sci.**, v.15, p.671–687, 2022. Disponível em: <https://doi.org/10.1007/s12145-021-00708-0>.

VILLARINI, G.; SERINALDI, F.; SMITH, J. A.; KRAJEWSKI, W. F. On the stationarity of annual flood peaks in the continental United States during the 20th century. **Water Resour. Res.**, v.45, n.8, 2009a. Disponível em: <https://doi.org/10.1029/2008WR007645>.

VILLARINI, G.; SMITH, J. A.; SERINALDI, F.; BALES, J.; BATES, P. D.; KRAJEWSKI, W. F. Flood frequency analysis for nonstationary annual peak records in an urban drainage basin. **Adv. Water Resour.**, v.32, n.8, p.1255–1266, 2009b. Disponível em: <https://doi.org/10.1016/j.advwatres.2009.05.003>.

VILLARINI, G.; SMITH, J. A.; NLETEKOS, A. A.; SCHWARZ, U. Annual maximum and peaks-over-threshold analyses of daily rainfall accumulation for Austria. **Journal of Geophysical Research**, v.116, 2011. Disponível em: <http://dx.doi.org/10.1029/2010JD015038>.

VILLELA, S. M.; MATTOS, A. **Hidrologia aplicada**. São Paulo: McGraw-Hill do Brasil, 1975. 245p.

VOGEL, R. M.; YAINDL, C.; AND WALTER, M. Nonstationarity: Flood magnification and recurrence reduction factors in the United States. **J. Am. Water Resour. Assoc.**,

v.47, n.3, p.464-474, 2011. Disponível em: <https://doi.org/10.1111/j.1752-1688.2011.00541.x>.

WANG, Wei. LIN, Hui. CHEN, Nengcheng CHEN, Zeqiang (2021). Evaluation of multi-source precipitation products over the Yangtze River Basin, **Atmospheric Research**, v.249, 2021. Disponível em: <https://doi.org/10.1016/j.atmosres.2020.105287>.

WASKO, C.; NATHAN, R.; STEIN, L.; O'SHEA, D. Evidence of shorter more extreme rainfalls and increased flood variability under climate change. **Journal of Hydrology**, v.603, 2021. Disponível em: [10.1016/j.jhydrol.2021.126994](https://doi.org/10.1016/j.jhydrol.2021.126994).

WORLD BANK. **World Development Report 2018: Learning to Realize Education's Promise**. Washington, D.C.: World Bank, 2018.

WI, S.; VALDES, J. B.; STEINSCHNEIDER, S.; KIM, T.-W. Non-stationary frequency analysis of extreme precipitation in South Korea using peaks-over-threshold and annual maxima. **Stochastic Environmental Research and Risk Assessment**, v.30, n.2, p.583-606, 2016. Disponível em: <http://dx.doi.org/10.1007/s00477-015-1180-8>.

XAVIER, A. C. F.; BLAIN, G. C.; MORAIS, M. V. B. DE; SOBIERAJSKI, G. R. Selecting "the best" nonstationary Generalized Extreme Value (GEV) distribution: on the influence of different number of GEV-models. **Agrometeorology**, v.78, n.4, p.606-621, 2019. Disponível em: <https://doi.org/10.1590/1678-4499.20180408>.

XAVIER, A. C. F.; RUDKE, A. P.; FUJITA, T.; BLAIN, G. C.; MORAIS, M. V. B. DE; ALMEIDA, D. S. DE; RAFEE, S. A. A.; MARTINS, L. D.; SOUZA, R. A. F. DE; FREITAS, E. D. DE; MARTINS, J. A. Stationary and non-stationary detection of extreme precipitation events and trends of average precipitation from 1980 to 2010 in the Paraná River basin, Brazil. **International Journal of Climatology**, v.40, n.2, p.1197–1212, 2020. Disponível em: <https://doi.org/10.1002/joc.6265>.

XAVIER, A. C. F.; RUDKE, A. P.; SERRÃO, E. A. O.; TERASSI, P. M. B. PONTES, P. R. M. Evaluation of Satellite-Derived Products for the Daily Average and Extreme Rainfall in the Mearim River Drainage Basin (Maranhão, Brazil). **Remote Sens.**, v.13, n.21, 2021. Disponível em: <https://doi.org/10.3390/rs13214393>.

YILMAZ, A.G.; HOSSAIN, I.; PERERA, B.J.C. Effect of climate change and variability on extreme rainfall intensity-frequency-duration relationships: a case study of Melbourne. **Hydrol. Earth Syst. Sci.**, v.18, p.4065-4076, 2014.

YU, Q.; WANG, Y.; LI, N. Extreme Flood Disasters: Comprehensive Impact and Assessment. **Water (Switzerland)**, v. 14, n. 8, 2022. Disponível em: <https://doi.org/10.3390/w14081211>.

## APÊNDICE A

Quadro 7 - Estações pluviométricas da ANA utilizadas

N	Código	Latitude	Longitude	Nome	Município	Período
1	1439001	-14,8103	-39,4714	Lomanto Junior	Ibicaraí	1981 a 31/03/2023
2	1439023	-14,6778	-39,3894	Itajuípe (Pirají)	Itajuípe	1981 a mar2023
3	1439044	-14,9589	-39,8075	Santa Cruz da Vitória	Santa Cruz da Vitória	1981 a mar 2023
4	1439089	-14,8694	-39,5883	Ibicaraí	Ibicaraí	1985 a mar 2023
5	1539002	-15,0922	-39,3456	São José	São José da Vitória	1981 a mar 2023
6	1539006	-15,9608	-39,5261	Itapebi	Itapebi	1981 a mar 2023
7	1539010	-15,5642	-39,3017	Mascote	Mascote	1981 a mar 2023
8	1539014	-15,6033	-39,5169	Fazenda Nancy	Camacan	1981 a mar2023
9	1539022	-15,4253	-39,4928	Camacan (Vargito)	Camacan	1981 a mar 2023
10	1639000	-16,2650	-39,5833	Mundo Novo	Eunápolis	1981 a jan 2023
11	1739001	-17,3503	-39,2200	Prado	Prado	1981 a abr 2023
12	1739005	-17,0450	-39,5447	Itamaraju	Itamaraju	1981 a abr 2023
13	1739006	-17,8081	-39,6625	Helvécia (EFBM)	Nova Viçosa	1981 a abr 2023
14	1739010	-17,5156	-39,2275	Alcobaça	Alcobaça	1981 a fev 2023
15	1740001	-17,8375	-40,3772	Nanuque - Montante	Nanuque - MG	1981 a jan 2023
16	1740005	-17,3722	-40,2258	Medeiros Neto	Medeiros Neto	1981 a abr 2023
17	1740006	-17,1875	-39,9822	São José do Prado	Vereda	1981 a abr 2023
18	1740008	-17,1633	-40,3267	Itanhém	Itanhém	1981 a abr 2023
19	1740026	-17,3203	-40,6761	São Pedro do Pampá	Umburatiba - Mg	1981 a abr 2023
20	1839000	-18,2994	-39,9586	Morro D'anta (Pedro Canário)	Conceição da Barra – ES	1981 a abr 2023
21	1840012	-18,1456	-40,1439	Fazenda Limoeiro	Montanha - ES	1981 a abr 2023
22	1539016	-15,1544	-39,7692	Fazenda Manaus	Itaju do Colônia	1981 a out 2022
23	1439002	-14,8597	-39,6583	Floresta Azul	Floresta Azul	1981 a nov 2022
24	1539008	-15,1389	-39,7242	Itajú do Colônia	Itajú do Colônia	1981 a jun 2021
25	1339000	-13,6011	-39,4917	Santa Luzia	Wenceslau Guimarães	1981 a mar 2023
26	1339012	-13,8106	-39,1692	Ituberá	Ituberá	1981 a mar 2023
27	1339020	-13,5669	-39,0019	Aratuípe	Aratuípe	1981 a mar 2023
28	1339027	-13,6847	-39,4789	Wenceslau Guimarães	Wenceslau Guimarães	1981 a mar 2023
29	1339038	-13,3672	-39,0772	Valença	Valença	1981 a ago 2021
30	1339044	-13,5967	-39,1247	Nilo Peçanha	Nilo Peçanha	1981 a mar 2023
31	1439006	-14,3267	-39,4686	Pedrinhas	Gongogi	1981 a mar 2023

Fonte: Autor