

UNIVERSIDADE FEDERAL DE MINAS GERAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM SANEAMENTO,
MEIO AMBIENTE E RECURSOS HÍDRICOS

CARACTERIZAÇÃO DAS DIFERENÇAS ENTRE
PRECIPITAÇÕES ESTIMADAS POR SATÉLITE
E OBTIDAS POR PLUVIÔMETROS

Fernando Henrique Pires de Oliveira

Belo Horizonte

2019

**CARACTERIZAÇÃO DAS DIFERENÇAS ENTRE
PRECIPITAÇÕES ESTIMADAS POR SATÉLITE E
OBTIDAS POR PLUVIÔMETROS**

Fernando Henrique Pires de Oliveira

Fernando Henrique Pires de Oliveira

**CARACTERIZAÇÃO DAS DIFERENÇAS ENTRE
PRECIPITAÇÕES ESTIMADAS POR SATÉLITE E
OBTIDAS POR PLUVIÔMETROS**

Dissertação apresentada ao Programa de Pós-graduação em Saneamento, Meio Ambiente e Recursos Hídricos da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Mestre em Saneamento, Meio Ambiente e Recursos Hídricos.

Área de concentração: Recursos Hídricos

Linha de pesquisa: Modelagem de Processos Hidrológicos

Orientador: Francisco Eustáquio Oliveira e Silva

Belo Horizonte
Escola de Engenharia da UFMG

2019

O48c	<p>Oliveira, Fernando Henrique Pires de. Caracterização das diferenças ente precipitações estimadas por satélite e obtidas por pluviômetros [recurso eletrônico] / Fernando Henrique Pires de Oliveira. – 2019. 1 recurso online (xi, 119 f.: il., color.) : pdf.</p> <p>Orientador: Francisco Eustáquio Oliveira e Silva.</p> <p>Dissertação (mestrado) - Universidade Federal de Minas Gerais, Escola de Engenharia.</p> <p>Apêndices: f. 109-119.</p> <p>Bibliografia: f. 94-108. Exigências do sistema: Adobe Acrobat Reader.</p> <p>1. Engenharia sanitária - Teses. 2. Recursos hídricos - Desenvolvimento - Teses. 3. Pluviômetros - Teses. 4. Meteorologia por satélite - Teses. 5. Paranaíba, Rio, Bacia (MG) - Teses. I. Silva, Francisco Eustáquio Oliveira e. II. Universidade Federal de Minas Gerais. Escola de Engenharia. III. Título.</p> <p style="text-align: right;">CDU: 628(043)</p>
------	---



UNIVERSIDADE FEDERAL DE MINAS GERAIS

Escola de Engenharia

Programa de Pós-Graduação em Saneamento, Meio Ambiente e Recursos Hídricos

Avenida Antônio Carlos, 6627 - 4º andar - 31270-901 - Belo Horizonte - BRASIL

Telefax: 55 (31) 3409-1882 - posgrad@desa.ufmg.br

http://www.smarh.eng.ufmg.br

FOLHA DE APROVAÇÃO

Caracterização das Diferenças Entre Precipitações Estimadas Por Satélite e Obtidas Por Pluviômetros

FERNANDO HENRIQUE PIRES DE OLIVEIRA

Dissertação defendida e aprovada pela banca examinadora constituída pelos Senhores:

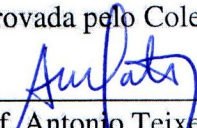

Prof. FRANCISCO EUSTÁQUIO OLIVEIRA E SILVA


Prof. TACIANA TOLEDO DE ALMEIDA ALBUQUERQUE

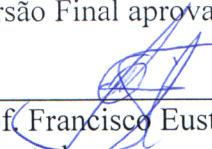

Prof. VÉBER AFONSO FIGUEIREDO COSTA


Prof. OTTO CORRÊA ROTUNNO FILHO

Aprovada pelo Colegiado do PG SMARH


Prof. Antonio Teixeira de Matos
Coordenador

Versão Final aprovada por


Prof. Francisco Eustáquio Oliveira e Silva
Orientador

Belo Horizonte, 27 de agosto de 2019.

AGRADECIMENTOS

A Deus, por me assegurar saúde e fé para vencer essa jornada de sacrifícios e abrir os caminhos em todos os momentos.

Aos meus pais, Wilson e Luzia, por sempre propiciarem tudo do melhor e nunca medir esforços para me apoiar na busca pelos meus objetivos. Além de

A minha querida irmã Ana Paula, pelo simples fato de ser a melhor irmã do mundo e quem mais me entende. Além do constante incentivo ao meu crescimento profissional.

Aos incríveis amigos Adriano, Keigo, Moreira e Mateus que por mais de 25 anos de amizade, moldaram resiliência e perspicácia, pela proximidade de pensamentos e ideias.

Aos professores do EHR, por compartilhar suas sabedorias através do exemplo, algo meritório no meio acadêmico, as quais foram essenciais para que eu me debruce cada vez mais ao mundo das águas.

Ao meu orientador Francisco, em especial, por compartilhar seu conhecimento, sua dedicação, estar sempre presente quando necessário e por me acalmar nos momentos mais difíceis.

À melhor turma de Mestrado (2017/1º) que o EHR teve a honra de conhecer: Luisa, Karine, Hamzi, Garcia, Lívia e Milena. Aqueles que andaram pelo corredor e não puderam ficar até o final dessa jornada: Bonjardim, Rogério, Bismarck e Mauro. E tantos outros não citados, mas que eu me lembro e são importantes pra mim de qualquer forma.

Ao povo brasileiro, o qual financiou os meus estudos de qualidade e que, infelizmente, poucos terão acesso. Portanto, aumentou o meu compromisso de tornar esse estudo mais acessível a eles.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelos meses concedidos de bolsa.

Aos membros da banca examinadora.

RESUMO

O monitoramento das precipitações traz subsídios imprescindíveis para o planejamento e operação de diversos setores da sociedade. Entretanto, devido a sua intermitência, uma representação precisa de sua variabilidade espaço-temporal é extremamente difícil. As estimativas de precipitação por satélite são uma alternativa para superar essa objeção. Entretanto, essas possuem incertezas associadas as suas estimativas.

Neste trabalho, foram avaliados o desempenho de três produtos de satélite (TMPA 3B42, CMORPHv1.0-CRT e PERSIANN), por meio de índices categóricos (POD, FAR e fBIAS) e métricas contínuas (MAE e KGE') nas escalas temporais diária, mensal e anual sobre a bacia do rio Paranaíba. Posteriormente, foram aplicadas técnicas para a correção do viés dessas estimativas com o intuito de aproximá-las de observações *in situ*.

Os resultados demonstram que os produtos apresentam boa capacidade de identificar eventos de chuva, mas baixa precisão em classificar suas intensidades, e não há um único produto que desempenhe superiormente em todas as análises realizadas. Porém, em termos médios, o produto TMPA se sobressai aos demais em todas as escalas temporais. O coeficiente de eficiência de Kling-Gupta modificado (KGE') mostrou-se ser um índice de avaliação útil, porque decompõe o erro em parâmetros de correlação linear, viés e variabilidade.

As técnicas de correção de viés avaliadas foram capazes de corrigir o primeiro momento das distribuições dos dados de satélites. O mapeamento de quantis por distribuições não paramétricas, em especial, também foi capaz de aprimorar o segundo momento das distribuições. Entretanto, o erro médio absoluto se manteve praticamente inalterado. Conclui-se que, apesar da evolução contínua das estimativas de precipitação por satélite, seu emprego em estudos hidrológicos deve ser precedido de uma análise criteriosa, orientada pelos objetivos e importância relativa da introdução de novas fontes de incertezas à análise.

Palavras-chave: pluviômetros, estimativas de precipitação por satélites; erros sistemáticos; bacia do rio Paranaíba; correção de viés.

ABSTRACT

The monitoring of precipitation brings essential subsidies for the planning and operation of various sectors of society. However, due to its intermittence, an accurate representation of its spatiotemporal variability is extremely difficult. Satellite precipitation estimates are an alternative to overcome this objection. However, these have uncertainties associated with their estimates.

In this work, we evaluated the performance of three satellite products (TMPA 3B42, CMORPHv1.0-CRT and PERSIANN) using categorical indices (POD, FAR and fBIAS) and continuous metrics (MAE and KGE') on daily, monthly and annual time scales on the Paranaíba river basin. Subsequently, techniques were applied to correct the bias of these estimates in order to approximate them with *in situ* observations.

The results show that the products have good ability to identify rainfall events, but poor accuracy in classifying their intensities, and there is not a single product that performs superiorly in all analyzes performed. However, on average, the TMPA product outperforms the others on all time scales. The modified Kling-Gupta efficiency coefficient (KGE') proved to be a useful evaluation index because it decomposes the error into linear correlation, bias and variability components.

The bias correction techniques evaluated were able to correct the first moment of satellite data distributions. The quantile mapping by nonparametric distributions, in particular, was also able to improve the second moment of the distributions. However, the mean absolute error remained virtually unchanged. It is concluded that, despite the continuous evolution of satellite precipitation estimates, its use in hydrological studies should be preceded by a careful analysis, guided by the objectives and relative importance of introducing new sources of uncertainty to the analysis.

Keywords: rain gauges, satellite rainfall estimates; systematic errors; Paranaíba river basin; bias correction.

SUMÁRIO

LISTA DE FIGURAS	V
LISTA DE TABELAS	VII
LISTA DE ABREVIATURAS, SIGLAS E SÍMBOLOS	IX
1. INTRODUÇÃO	1
2. OBJETIVOS	5
2.1 OBJETIVO GERAL.....	5
2.2 OBJETIVOS ESPECÍFICOS	5
3. REVISÃO DA LITERATURA	6
3.1 PRECIPITAÇÕES: FORMAÇÃO, TIPOS E TÉCNICAS CONVENCIONAIS DE MEDIÇÃO	6
3.2 ESTIMATIVAS DE PRECIPITAÇÃO POR SENSORIAMENTO REMOTO	16
3.2.1 Algoritmos do espectro visível e do infravermelho.....	23
3.2.2 Algoritmos do espectro micro-ondas	25
3.2.3 Algoritmos multiespectrais.....	26
3.3 INCERTEZAS NAS ESTIMATIVAS DE PRECIPITAÇÃO POR SATÉLITES	28
3.3.1 Divergências na escala temporal.....	29
3.3.2 Divergências na escala espacial.....	30
3.3.3 Correção de viés dos produtos de satélite.....	36
4. METODOLOGIA	40
4.1 ETAPA 1 – IDENTIFICAÇÃO DAS DIFERENÇAS ENTRE OS PLUVIÔMETROS E PRODUTOS DE SATÉLITE	41
4.1.1 Definição da área de estudo.....	41
4.1.2 Obtenção e pré-análise dos dados pluviométricos	46
4.1.3 Definição dos produtos de satélites	48
4.1.4 Análise comparativa dos produtos de satélite e in situ.....	54
4.2 ETAPA 2 – APLICAÇÃO DE TÉCNICAS PARA CORREÇÃO DE VIÉS.....	60
4.2.1 Regressão linear simples.....	60
4.2.2 Mapeamento de quantis.....	61
5. RESULTADOS E DISCUSSÃO	62
5.1 AVALIAÇÃO DE DESEMPENHO DOS PRODUTOS DE SATÉLITE	63
5.1.1 Desempenho na escala diária.....	63
5.1.2 Desempenho na escala mensal	74
5.1.3 Desempenho na escala anual	80
5.2 AVALIAÇÃO DAS TÉCNICAS DE CORREÇÃO DE VIÉS.....	81
5.2.1 Avaliação da correção de viés na escala diária por estação.....	81
5.2.2 Avaliação da correção de viés na escala mensal por UGH.....	86
6. CONCLUSÕES E RECOMENDAÇÕES	90
7. REFERÊNCIAS BIBLIOGRÁFICAS	94
APÊNDICES	109

LISTA DE FIGURAS

Figura 3.1 – Classificação de nuvens baseadas na sua altitude em relação a superfície.	9
Figura 3.2 – Pluviômetro modelo <i>Ville de Paris</i>	13
Figura 3.3 – Diferentes tipos de pluviômetros e os efeitos do vento sobre eles.	14
Figura 3.4 – Número de estações pluviométricas nas diferentes bases de dados em função do tempo.	16
Figura 3.5 – Espectro eletromagnético.	17
Figura 3.6 – Representação gráfica da técnica mapeamento de quantis.	38
Figura 4.1 – Fluxograma da metodologia adotada.	40
Figura 4.2 – Precipitação média mensal sobre a bacia do Rio Paranaíba.	42
Figura 4.3 – Hipsometria e unidades geomorfológicas.	44
Figura 4.4 – Uso e ocupação do solo nas UGH.	44
Figura 4.5 – Unidades de Gestão Hídrica (UGH) da bacia do rio Paranaíba.	45
Figura 4.6 – Localização das estações pluviométricas empregadas.	48
Figura 4.7 – Compatibilização temporal dos arquivos de satélite e pluviômetros da ANA.	52
Figura 4.8 – Visão gráfica do método BWI numa grade 2x2.	54
Figura 4.9 – Exemplo gráfico da técnica mapeamento de quantis.	61
Figura 5.1 – Mediana da métrica POD de todos os produtos por classes de eventos.	64
Figura 5.2 – Mediana da métrica FAR de todos os produtos por classes de eventos.	65
Figura 5.3 – Mediana da métrica fBIAS de todos os produtos por classes de eventos.	67
Figura 5.4 – <i>Box plots</i> da métrica MAE de todos os produtos na escala diária por estação. ...	68
Figura 5.5 – Medianas da métrica MAE de todos os produtos de satélite por classe de eventos.	69
Figura 5.6 – Mapas da métrica KGE' na escala diária para todos os produtos de satélite.	70
Figura 5.7 – Mapa de localização das estações sobre a hipsometria da bacia do rio Paranaíba e histograma da altimetria da métrica KGE' por estação para o produto PERSIANN.	73
Figura 5.8 – <i>Box plots</i> da métrica MAE mensal por estação para todos os SRE.	75
Figura 5.9 – <i>Box plots</i> da métrica KGE' e suas componentes (r , β e γ) mensais por estação para cada SRE.	76
Figura 5.10 – Quantitativo de estações pluviométricas por UGH.	77
Figura 5.11 – <i>Box plots</i> da métrica MAE mensal por UGH para todos os SRE.	77
Figura 5.12 – Mapas da métrica KGE' mensal por UGH para todos os produtos.	78
Figura 5.13 – <i>Box plots</i> da métrica MAE mensal por UGH por mês para todos os SRE.	79

Figura 5.14 – Diagramas de dispersão entre pluviômetro e produto CMORPH antes e após a correção por ambas as técnicas para duas estações.	83
Figura 5.15 – Componentes da métrica KGE' antes e após a correção de viés no período de validação para todos os produtos.....	84
Figura 5.16 – Gráfico de chuva acumulada para a estação 1946005 no período de validação de ambas as técnicas de correção de viés para o produto TMPA.....	85
Figura 5.17 – Funções empíricas de distribuição acumulada da estação 1946005 antes e após a correção de viés para o produto TMPA.....	86
Figura 5.18 – Componentes β e γ antes e após a correção de viés na escala mensal para todos os produtos.....	87
Figura 5.19 – Gráfico de chuva acumulada para a UGH-Corumbá no período de validação de ambas as técnicas de correção de viés para o produto CMORPH.....	88
Figura 5.20 – Funções empíricas de distribuição acumulada da UGH-Distrito Federal antes e após a correção de viés para o produto CMORPH.	88

LISTA DE TABELAS

Tabela 3.1 – Composição de gases da atmosfera próxima a superfície terrestre.	6
Tabela 3.2 – Principais grupos de nuvens e seus tipos.	8
Tabela 3.3 – Características típicas de um satélite de cada tipo: GEO e LEO.	19
Tabela 3.4 – Principais satélites meteorológicos em operação.	21
Tabela 3.5 – Principais sensores imageadores e sondadores utilizados pelos produtos de satélite.	22
Tabela 3.6 – Resumo dos principais produtos de precipitação por satélite multissensorial e seus atributos.	28
Tabela 3.7 – Algumas técnicas de interpolação espacial.	32
Tabela 4.1 – Recomendações de densidade mínima de estações por unidade fisiográfica.	42
Tabela 4.2 – Participação das unidades da federação na bacia do rio Paranaíba.	43
Tabela 4.3 – Critérios empregados durante a análise preliminar dos dados de pluviômetros.	47
Tabela 4.4 – Principais características dos produtos de satélite utilizados.	51
Tabela 4.5 – Proposta de classificação de eventos de chuva baseados na intensidade diária.	55
Tabela 4.6 – Tabela de contingência para categorizar as frequências de eventos.	55
Tabela 5.1 – Quantitativo de dados utilizados por escala temporal.	63
Tabela 5.2 – Estatísticas descritivas dos dados de chuva diários para todas as séries.	63
Tabela 5.3 – Distribuição dos dados diários em classes de eventos.	64
Tabela 5.4 – Medianas das componentes da métrica KGE' diária de todos os produtos de satélite.	71
Tabela 5.5 – Medianas das componentes KGE' por classes de eventos de todos os produtos de satélite.	72
Tabela 5.6 – Medianas das métricas de acurácia de todos os SRE analisados na escala diária.	74
Tabela 5.7 – Estatísticas descritivas para a série de dados mensais por estação pluviométrica para todos os medidores.	74
Tabela 5.8 – Estatísticas descritivas para a série de dados anuais por estação pluviométrica para todos os medidores.	80
Tabela 5.9 – Medianas das métricas MAE, KGE' e suas componentes na escala anual para todos os SRE.	81
Tabela 5.10 – Medianas das métricas MAE e KGE' antes e após a correção de viés para todos os produtos de satélite.	82

Tabela 5.11 - Métricas MAE e KGE' antes a após a correção de viés para todos os produtos de satélite.....	86
---	----

LISTA DE ABREVIATURAS, SIGLAS E SÍMBOLOS

ABI	Advanced Baseline Imager
AHI	Advanced Himawari Imager
AMSU	Advanced Microwave Sounding Unit
AVHRR	Advanced Very High Resolution Radiometer
ANA	Agência Nacional das Águas
AE	Auto-Estimator
BWI	Bilinear weighted interpolation method
CPTEC	Centro de Previsão de Tempo de Estudos Climáticos
CEMADEN	Centro Nacional de monitoramento e Alertas de Desastres Naturais
CHIRPS	Climate Hazards Infrared Precipitation with Stations
CPC	Climate Prediction Center
CMORPH	Climate Prediction Center MORPHing technique
CPR	Cloud Profiling Radar
CAPSAT	Clouds-Aerosols-Precipitation Satellite Analysis Tool
CoSch	Combined Scheme algorithm
COMS	Communication, Ocean, and Meteorological Satellite
DECEA	Departamento de Controle e Espaço Aéreo
DPR	Dual-frequency Precipitation Radar
EUMETSAT	European Organisation for the Exploitation of Meteorological Satellites
FAR	<i>False alarm</i> ratio
fBIAS	Frequency bias
GOMS	Geostationary Operational Meteorological Satellite
GOES	Geostationary Operational Environmental Satellite
GEO	Geosynchronous Equatorial Orbit
GPCC	Global Precipitation Climatology Centre
GPM	Global Precipitation Measurement
GSMaP	Global Satellite Mapping of Precipitation
GPROF	Goddard Profiling
G-IMAGER	GOES Imager
GMSRA	GOES Multispectral Rainfall Algorithm
GPI	GOES Precipitation Index
G-SOUNDER	GOES Sounder
GMI	GPM Microwave Imager
HIRS	High-resolution Infra Red Sounder
HE	Hydro-Estimator
ISRO	Indian Space Research Organization
IRAS	Infrared Atmospheric Sounder
IV	Infravermelho
IV_P	Infravermelho próximo
IPMET	Instituto de Pesquisas Meteorológicas
INMET	Instituto Nacional de Meteorologia
INPE	Instituto Nacional de Pesquisas Espaciais

IMERG	Integrated Multi-satellitE Retrievals for Global Precipitation Measurement
KARI	Korea Aerospace Research Institute
LEO	Low Earth Orbit
MAE	Mean absolute error
MAP	Mean areal precipitation
MO	Microwave
MHS	Microwave Humidity Sounding
MWRI	Microwave Radiation Imager
MWTS	Microwave Temperature Sounder
KGE'	Modified Kling-Gupta efficiency statistic
NASA	National Aeronautics and Space Administration
NOAA	National Oceanic and Atmospheric Administration
OMM	Organização Meteorológica Mundial
PERSIANN	Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks
PR	Precipitation Radar
POD	Probability of detection
RHN	Rede Hidrometeorológica Nacional
RCM	Regional Climate Model
SRE	Satellite Rainfall Estimates
SNIRH	Sistema Nacional de Informação em Recursos Hídricos
SSMIS	Special Sensor Microwave - Imager/Sounder
SEVIRI	Spinning Enhanced Visible Infra-Red Imager
TIROS	Television and Infrared Observation Satellite
TMI	TRMM Microwave Imager
TMPA	TRMM Multi-satellite Precipitation Analysis
TRMM	Tropical Rainfall Measuring <i>Mission</i>
UGH	Unidades de Gestão Hídrica
UTC	Universal Time Coordinated
VIRR	Visible and Infra-Red Radiometer
Vis	Visível

1. INTRODUÇÃO

O ciclo hidrológico é o fenômeno global de circulação de água entre a atmosfera e superfície terrestre, impulsionado pelo fluxo de energia solar associado à gravidade e à rotação da Terra. A troposfera contém grande parte da mistura atmosférica de gases, vapor d'água e partículas em suspensão. É nesse estrato térmico da atmosfera que ocorrem os fenômenos meteorológicos de maior relevância. O vapor d'água, em especial, exerce um importante papel na regulação da temperatura do ar e na manutenção do equilíbrio energético global da Terra. Sua condensação em núcleos está associada a formação de várias formas de nebulosidade. Quando ativos, esses núcleos passam a aglutinar moléculas de vapor d'água e permitem a formação de gotículas de água. Um eventual aumento da massa e do diâmetro dessas gotículas em suspensão no interior das nuvens pode ocasionar o fenômeno da precipitação (YNOUE *et al.*, 2017).

A maior parte das precipitações pode ser classificada em dois grupos, conforme a sua função no sistema hidrológico: sistemas convectivos e estratiformes. Sistemas convectivos estão associados a fortes campos verticais de vento e altas taxas pluviométricas instantâneas; enquanto nos sistemas estratiformes predominam-se áreas de cobertura extensas, baixas velocidades verticais de vento, homogeneidade horizontal e taxas de precipitação menores (YNOUE *et al.*, 2017). Devido às diferenças existentes entre os dois sistemas, ser capaz de classificá-los contribui para uma melhor estimativa de precipitação obtida por meio dos dados medidos.

A precipitação desempenha papel crucial na compreensão do mecanismo de distribuição global de água e energia e é o principal *input* de modelos hidrometeorológicos e estudos climáticos. Em situações extremas, seu excesso pode provocar inundações, as quais transfiguram-se em danos materiais como prejuízos à agricultura e inundações urbanas. Do contrário, regiões em escassez severa de precipitações sofrem por perda de cultivos, miséria humana, e ocasionam migração de animais (VARMA, 2018).

A precipitação é provavelmente o fenômeno hidrológico mais amplamente registrado (STRANGWAYS, 2010). Tais informações são necessárias para que, por exemplo, meteorologistas a utilizem em modelos climáticos, hidrólogos simulem efeitos do ciclo da água sobre bacias hidrográficas e para que oceanógrafos investiguem o impacto das chuvas na salinidade das águas superficiais oceânicas, dentre outras aplicações (VARMA, 2018).

Os pluviômetros são os medidores mais comuns para quantificação pontual da chuva, a forma líquida de precipitação mais provável de ocorrência mais frequente nas regiões tropicais. Entretanto, aspectos relacionados à instalação desses equipamentos, como topografia e efeitos de vento locais, podem prejudicar a confiabilidade de suas medidas (STRANGWAYS, 2010). Segundo a Organização Meteorológica Mundial (OMM), as diferenças no quantitativo de precipitação registrado por esse instrumento podem estar acima de 30% do que de fato chega à superfície (OMM, 2014).

Além dessas incertezas inerentes ao pluviômetro, a distribuição espacial não uniforme de sua instalação, a baixa resolução temporal de coleta de seus dados e a alta diversidade de coletores instalados nas redes de monitoramento acarretam limitações de aplicação e comparação de seus registros. Ademais, pluviômetros instalados nos oceanos e nas áreas polares e montanhosas, as quais são de interesse no contexto das variações climáticas, são bastante escassos e de difícil manutenção (HONG *et al.*, 2018). Além disso, segundo os relatos de Becker *et al.* (2013), o número de pluviômetros em operação está em redução contínua ao redor do mundo.

Segundo Sun *et al.*, (2018), o desenvolvimento das técnicas de sensoriamento remoto possibilitou o monitoramento das precipitações de forma global. Radares e satélites meteorológicos são os principais instrumentos capazes de estimá-la via sensoriamento remoto. Após a 2ª Guerra Mundial, os radares meteorológicos aprimoraram as mensurações das escalas espaciais e temporais das precipitações, e vários estudos em escala regional foram realizados utilizando essas informações (BECK *et al.*, 2019; PELEG *et al.*, 2018). Contudo, os radares meteorológicos são inadequados para monitoramento global da precipitação, pois o seu domínio espacial é limitado, principalmente em regiões oceânicas, remotas e em desenvolvimento (HONG *et al.*, 2018).

Atualmente, a única forma prática de monitoramento global da precipitação é por meio de satélites meteorológicos (TAPIADOR *et al.*, 2017). Ainda segundo Tapiador *et al.* (2017), as estimativas de precipitação por satélite possuem vantagens aos pluviômetros e radares em termos de cobertura espacial, principalmente em estudos realizados para grandes bacias. Além do mais, os satélites operam de forma mais contínua e uniforme, o que evita o alto custo de manutenção das redes de observação terrestre.

A bordo dos satélites estão os sensores capazes de extrair características das nuvens e produzir estimativas de precipitação. Segundo Varma (2018), essas estimativas globais são

majoritariamente baseadas em sensores passivos de micro-ondas passivas (MO), de ondas do infravermelho (IV) e de algoritmos que mesclam as informações de ambas e são conhecidos por multiespectrais. Comumente, sensores de infravermelho estão a bordo de satélites geoestacionários (GEO, do inglês *Geosynchronous Equatorial Orbit*) que fornecem estimativas de precipitação em altas resoluções temporais contudo, a precisão dessas estimativas geralmente não é ótima quando comparada a outros tipos de sensores, devido à ligação indireta entre os sinais de infravermelho e a precipitação. Os sensores de micro-ondas passivas estão a bordo de satélites em órbita baixa (LEO, do inglês *Low Earth Orbit*) e fornecem estimativas de precipitação baseadas em diâmetro médio das partículas líquidas e de gelo presentes nas nuvens. No entanto, os satélites LEO observam uma mesma região cerca de duas vezes ao dia.

Atualmente, alguns países como os Estados Unidos e a China, tentam implementar sensores MO em satélites GEO que, se efetivado, promoverão a capacidade de monitorar as chuvas com maior precisão em relação a geração atual (HONG *et al.*, 2018). Também há uma forte tendência no uso de sensores de micro-ondas ativas (radares), os quais fornecem estimativas volumétricas mais precisas de precipitação e neve. Exemplos desses últimos são o *Precipitation Radar* (PR) de frequência Ku que operou a bordo do satélite *Tropical Rainfall Measuring Mission* (TRMM) (HUFFMAN *et al.*, 2007), o *Cloud Profiling Radar* (CPR) de frequência W a bordo do *CloudSat* (KUBOTA *et al.*, 2007) e o atual *Dual-frequency Precipitation Radar* (DPR) de frequência dupla Ku/Ka a bordo do *Global Precipitation Mission* (GPM) (HOU *et al.*, 2014).

Com a evolução natural dessa tecnologia e o lançamento da missão TRMM em novembro de 1997, houve um aumento na disponibilidade de produtos de precipitação por satélite. Dentre os mais relevantes se pode citar o produto *TRMM Multi-satellite Precipitation Analysis* (TMPA) (HUFFMAN *et al.*, 2007), o *Climate Prediction Center (CPC) MORPHing*, ou produto CMORPH (JOYCE *et al.*, 2004), o produto *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks* (PERSIANN) (SOROOSHIAN *et al.*, 2000), o *Global Satellite Mapping of Precipitation* (GSMaP) (KUBOTA *et al.*, 2007) e, mais recentemente, os produtos *Climate Hazards Infrared Precipitation with Stations* (CHIRPS) (FUNK *et al.*, 2015) e o *Integrated Multi-satellitE Retrievals for Global Precipitation Measurement* (IMERG) (GADELHA *et al.*, 2019).

Vários produtos de precipitação por satélite foram aplicados em diversas análises hidrometeorológicas como, por exemplo, estabilidade de taludes (BRUNETTI *et al.*, 2018), estimativas da umidade do solo (CAI *et al.*, 2019), análise de frequência (GADO; HSU; SOROOSHIAN, 2017), prevenção de inundações (BEAUFORT; GIBIER; PALANY, 2019), modelagem hidrológica (FLEISCHMANN *et al.*, 2019), dentre outras (MAGGIONI; MEYERS; ROBINSON, 2016). Todavia, alguns desses estudos mostraram que, assim como quaisquer técnicas de medição, essas estimativas sensoriais detêm incertezas. Por conseguinte, diversos outros estudos avaliaram o desempenho dos produtos os comparando com dados de superfície (radares e pluviômetros), ditos de referência, para uma dada região a fim de identificar a magnitude desses erros (BAI; LIU, 2018; BECK *et al.*, 2017, 2019). Devido as elevadas incertezas identificadas nos resultados de estudos prévios, outros trabalhos propuseram técnicas com o intuito de corrigir o viés entre esses estimadores (GUILLOD *et al.*, 2018; WORQLUL *et al.*, 2018).

A bacia do rio Paranaíba, que vem apresentando um expressivo desenvolvimento nos últimos anos, se consolida cada vez mais como um importante eixo logístico, conectando as regiões Sudeste e Centro-Oeste do Brasil, e também como uma fronteira agrícola em franca expansão, em especial para a produção de grãos, a qual se associa uma forte agroindústria principalmente da cadeia da cana-de-açúcar. Além disso, apresenta importante trecho navegável da Hidrovia do Paraná e um expressivo parque de geração hidrelétrica, que é complementada pela atividade industrial e forte concentração populacional nos centros urbanos, que abrigam cerca de 8,5 milhões de habitantes (ANA, 2015).

Dentro desse contexto, este trabalho propôs-se avaliar o desempenho de produtos de satélite sobre a bacia do rio Paranaíba, localizada no centro-oeste brasileiro. A eficácia de técnicas para correção do viés desses produtos também foi avaliada, admitindo-se os registros dos pluviômetros como referência. Por fim, a partir dos resultados alcançados, algumas considerações acerca do potencial de aplicação operacional desses estudos foram apresentadas.

2. OBJETIVOS

2.1 *Objetivo geral*

O objetivo geral do estudo é caracterizar as diferenças nas estimativas de precipitação por satélite e *in situ* (pluviômetros) para a bacia do rio Paranaíba.

2.2 *Objetivos específicos*

- Verificar como a precisão de um dado produto se altera para diferentes intensidades de precipitação por meio de índices categóricos;
- Avaliar quais produtos de satélite possuem o melhor desempenho na escala diária, mensal e anual perante a métricas de acurácia; e
- Aferir técnicas para correção temporal do viés nas estimativas de precipitação por satélite.

3. REVISÃO DA LITERATURA

3.1 Precipitações: formação, tipos e técnicas convencionais de medição

O ciclo hidrológico, ou ciclo da água, é o movimento contínuo da água presente nos oceanos, continentes (superfície e solo) e na atmosfera. Esse movimento é alimentado pela força da gravidade e pela energia do Sol, que provocam a evaporação das águas dos oceanos e dos continentes.

A primeira camada da atmosfera, a qual participa substancialmente desse ciclo, possui uma diversidade de condições físicas importantes. Sob condições normais de temperatura e pressão observadas ao nível médio do mar, é composta por cerca de 78% de nitrogênio e 21% de oxigênio, com pequenas quantidades de outros gases, como vapor de água e dióxido de carbono. As concentrações médias de gases na atmosfera seca são destacadas na Tabela 3.1.

Tabela 3.1 – Composição de gases da atmosfera próxima a superfície terrestre.

Gases permanentes		Gases variáveis	
Gás	Volume (ar seco) (%)	Gás	Volume (ar seco) (%)
Nitrogênio (N ₂)	78,08	Vapor d'água (H ₂ O)	0-4
Oxigênio (O ₂)	20,94	Dióxido de carbono (CO ₂)	0,039
Argônio (Ar)	1	Ozônio (O ₃)	0,00001
Neônio (Ne)	0,0018	Metano (CH ₄)	0,00017
Hélio (He)	0,0005	Óxido nitroso (N ₂ O)	0,00003
Hidrogênio (H ₂)	0,00006	Clorofluorcarboneto (CFC)	0,00000002

Fonte: adaptado de Ynoye *et al.* (2017).

Segundo Ynoye *et al.* (2017), as quantidades de nitrogênio e oxigênio na atmosfera são relativamente constantes próximo à superfície da Terra, sendo esses gases denominados permanentes, assim como o argônio, o neônio, o hélio e hidrogênio. Ao contrário desses gases, a concentração do vapor de água varia muito de lugar para lugar e de tempos em tempos. Próximo a superfície em regiões tropicais quentes e úmidas, o vapor de água pode representar até 4% dos gases atmosféricos, enquanto em áreas árticas mais frias sua concentração pode ser inferior a 1%.

A água é a única substância natural presente em todas as três fases da matéria nas temperaturas e pressões normalmente encontradas próximas da superfície terrestre. O intercâmbio entre essas fases envolve primordialmente a liberação ou o consumo de calor latente por uma massa de ar.

Isso proporciona outro comportamento incomum do vapor d'água: a possibilidade desse se condensar quando atinge o ponto de saturação, isto é, a quantidade máxima de vapor d'água que uma parcela do ar pode conter, a uma determinada temperatura e pressão (WANG, 2013).

Todavia, em 1875, o cientista francês Paul Jean Coulier, ao trabalhar com uma câmara de expansão, esclareceu que a condensação do vapor d'água não ocorreria a menos que houvesse material particulado no ar (WANG, 2013). Essas “impurezas” de fontes naturais (poeira carregada pelos ventos; micropartículas de sal evaporadas das ondas oceânicas; microrganismos (bactérias e fungos); fumaça produzida por incêndios florestais e atividades vulcânicas) e antrópicas (produtos de processos industriais e queima de combustíveis fósseis) presentes na atmosfera formam os denominados aerossóis (AHRENS; HENSON, 2017).

Em síntese, ocorre a formação de nuvens quando uma parcela de ar ascende para níveis onde a pressão atmosférica é menor e, por consequência, seu volume se expande. Essa expansão se dá às expensas da redução da energia interna e temperatura dessa parcela. Esse fenômeno é conhecido por resfriamento adiabático (YNOYE *et al.*, 2017). Os aerossóis desempenham papel determinante nesse processo, pois agem como núcleos de condensação (superfícies de contato) para a formação de gotículas de água e/ou cristais de gelo. Esses particulados visíveis (na forma líquida ou sólida) de água associados aos mecanismos de ascensão do ar formam as nuvens (AHRENS; HENSON, 2017).

As nuvens assumem vários formatos e tamanhos e ocorrem em alturas diferentes, ficando a maior parte limitada à troposfera. Ocasionalmente podem ocorrer nuvens na estratosfera, as quais são compostas de aerossóis de ácidos nítricos ou sulfúricos. Evidencia-se, também, a ocorrência de nuvens na mesosfera, as quais são denominadas mesosféricas polares, e formam-se a cerca de 50 a 86 quilômetros acima da superfície de nosso planeta (WANG, 2013).

Segundo Ahrens e Henson (2017), os principais fatores que intervêm na descrição do aspecto de uma nuvem são suas dimensões, forma, estrutura e textura, assim como sua luminosidade e cor. Estes fatores serão levados em consideração na descrição de cada uma das diferentes formas e características das nuvens. Na Tabela 3.2 são apresentadas as classificações gerais de quatro grupos de nuvens, adotadas pela OMM, as quais se baseiam em sua altura de base e desenvolvimento vertical. Na Figura 3.1 está uma imagem ilustrativa dessas nuvens.

Tabela 3.2 – Principais grupos de nuvens e seus tipos.

Classificação com base em: altura de base	Nome	Sigla	Composições típicas
Nuvens altas (6 a 18 km)	<i>Cirrostratus</i>	Cs	Principalmente cristais de gelo.
	<i>Cirrus</i>	Ci	Quase exclusivamente cristais de gelo.
	<i>Cirrocumulus</i>	Cc	Quase exclusivamente cristais de gelo; gotas de água fortemente super-resfriadas podem ocorrer, mas geralmente são rapidamente substituídas por cristais de gelo.
Nuvens médias (2 a 8 km)	<i>Altostratus</i>	As	Gotas de água e cristais de gelo. No caso mais completo, três partes sobrepostas podem ser distinguidas: <ul style="list-style-type: none"> • Parte superior - totalmente ou principalmente cristais de gelo; • Parte do meio - mistura de gotículas de água super-resfriadas e cristais de gelo; • Parte inferior - gotículas de água normais ou super-resfriadas.
	<i>Alto cumulus</i>	Ac	Quase invariavelmente de gotículas de água; quando a temperatura é muito baixa, cristais de gelo podem se formar.
Nuvens baixas (0 a 2 km)	<i>Stratus</i>	St	Geralmente pequenas gotículas de água; partículas de gelo a baixas temperaturas.
	<i>Stratocumulus</i>	Sc	Gotas de água; cristais de gelo podem estar presentes em clima extremamente frio.
	<i>Nimbostratus</i>	Ns	Composição semelhante a <i>Altostratus</i> .
Classificação com base em: Desenvolvimento vertical	Nome	Sigla	Composições típicas
	<i>Cumulus</i>	Cu	Principalmente gotículas de água; cristais de gelo podem formar nas partes com uma temperatura bem abaixo de 0 °C.
	<i>Cumulonimbus</i>	Cb	Gotículas de água e, especialmente na sua porção superior, cristais de gelo; as gotas de água podem ser substancialmente super-resfriadas.

Fonte: Adaptado de OMM (2018).

Baseando-se em Wang (2013), pode-se distinguir seis tipos de partículas com relação ao seu raio, presentes nas nuvens. São elas:

- Gotículas de nuvem: gotas de água que se mantêm suspensas. A faixa de tamanho típica é de alguns micrômetros até 400 μm e o tamanho característico é em torno de 10 μm ;
- Gotas de chuva: gotas de água que caem contra a corrente ascendente e podem eventualmente atingir o solo. O intervalo de tamanho típico é de algumas centenas de micrômetros a 3 mm e o tamanho característico é de cerca de 1 mm. Gotas de chuveiro são uma subcategoria de gotas de chuva com raio menor que 250 μm ;




Figura 3.1 – Classificação de nuvens baseadas na sua altitude em relação a superfície.

Fonte: Adaptado de OMM (2018).

- Cristais de gelo: referem-se às partículas relativamente limpas de gelo cristalino de formato predominantemente hexagonal. Os cristais de gelo típicos nas nuvens variam de algumas dezenas de micrômetros até algumas centenas de micrômetros. Eles são às vezes chamados de nuvem de gelo;
- Flocos de neve: partículas de gelo cristalino de tamanho relativamente grande que caem contra a fluxo ascendente. Eles podem ser monocristais ou agregados de cristais, sendo estes últimos frequentemente referidos como flocos de neve ou agregados de neve, e os primeiros como cristais de neve. A faixa de tamanho típica é de algumas centenas de micrômetros para cristais limpos a alguns centímetros para grandes flocos de neve. Alguns flocos de neve podem consistir de centenas de cristais individuais;
- Saraiva: às vezes também chamado de granizo macio. São os precursores do granizo e muitos têm forma cônica. Por convenção, uma saraiva deve ter menos de 5 mm de diâmetro;
- Granizo: são geralmente as maiores partículas em um sistema precipitante. Por convenção, um granizo deve ter mais que 5 mm de diâmetro, mas pode atingir mais de 15 cm de tamanho.

A descrição microestrutural das nuvens, a partir do estudo das dimensões das partículas listadas, é relevante para estimativas a partir de sensores remotos. Por exemplo, o eco do radar depende do tamanho, da forma, das características da superfície e da concentração dessas partículas nas nuvens. O estudo da microfísica das nuvens, entretanto, vai muito além do escopo deste

trabalho. Para leitores interessados em se aprofundar nesse tema, indica-se recorrer a Wang (2013) e Testik e Gebremichael (2010).

Precipitações

De acordo com Ahrens e Henson (2017), as gotículas de chuvisco, também chamadas de gotículas de nuvem, possuem diâmetro médio de 0,02 mm e seu crescimento por colisão e coalescência (aglomeração de gotas de diferentes diâmetros) fazem com que tenham massa suficiente (gotas com diâmetro superior a 1 mm) para vencer as forças de flutuação térmica. Essas partículas aglomeradas são denominadas hidrometeoros. Dessa forma, se as componentes verticais ascendentes do ar são suficientes para suportar o peso dos hidrometeoros, esses recebem a denominação comum de partículas de nuvem. Por outro lado, quando os hidrometeoros adquirem uma velocidade de queda superior a força de sustentação atmosférica, eles se tornam partículas precipitantes.

O Instituto Nacional de Meteorologia (INMET) considera precipitação todas as formas de água, líquida ou sólida, que caem das nuvens alcançando o solo: granizo, neve, orvalho, geada, chuvisco (neblina ou garoa) e chuva (YNOUE *et al.*, 2017). Neste trabalho, o termo precipitação será utilizado para se referir ao produto líquido da condensação das partículas da atmosfera que caem em direção ao solo, mais precisamente, a chuva.

As principais características da chuva são a sua duração, intensidade, altura e distribuições temporais e espaciais. A chuva, quando comparada a outras variáveis hidrológicas, apresenta uma elevada variabilidade no tempo (alteração da intensidade ao longo do evento, definido um local no espaço) e sua distribuição espacial não apresenta, necessariamente, um padrão uniforme. Logo, a ocorrência de chuva é um processo aleatório que não permite uma previsão determinística com grande antecedência. Portanto, o tratamento dos dados de precipitação para a grande maioria dos problemas hidrológicos é estatístico.

Segundo Ahrens e Henson (2017), no tocante ao mecanismo de formação (movimentação do ar e tempo de crescimento das gotículas), as chuvas podem ser classificadas das seguintes formas:

- **Convectivas:** são chuvas de grande intensidade e pequena duração, restritas a pequenas áreas e estão relacionadas a nuvens do tipo *cumulus* e *cumulonimbus*. São geradas a partir do aquecimento de ar úmido na superfície terrestre, criando camadas de ar em

equilíbrio instável. O ar aquecido pode ascender localmente de forma rápida, atingindo grandes altitudes, onde, devido às baixas temperaturas ocorre a condensação do vapor. As chuvas convectivas são características das regiões equatoriais, onde os ventos são fracos e os movimentos de ar essencialmente verticais, mas podem também ocorrer em regiões temperadas por ocasião do verão;

- **Orográficas:** são chuvas que ocorrem quando há elevação do ar quente e úmido, geralmente no sentido do oceano para o continente, devido ao encontro com alguma barreira topográfica. Ao se elevar, ocorre a condensação do vapor nas altas altitudes, formação de nuvens e ocorrência das chuvas. São chuvas de intensidade e duração variáveis e que ocorrem em áreas próximas das encostas;
- **Frontais ou ciclônicas:** estão associadas com o movimento das massas de ar de diferentes temperaturas, que fluem das regiões de alta pressão para baixa pressão (zonas de convergência), devido ao aquecimento desigual da superfície terrestre. Ao se encontrarem, a massa de ar mais quente se sobrepõe a mais fria, originando elevados gradientes de temperatura, pressão e umidade. A massa de ar quente, ao se elevar, é resfriada e o seu vapor d'água é condensado, produzindo chuvas de longa duração, baixa (a média) intensidade e que alcançam grandes áreas.

Os padrões de precipitação, particularmente, nas regiões tropicais, apresentam forte variação espacial e temporal. Os estudos de Marengo (1992, 2004), demonstraram que as precipitações sobre a bacia amazônica variam, inclusive, em escalas de tempo maiores como a interanual e a interdecadal. Já Syed *et al.* (2004), analisaram a contribuição das variáveis hidrológicas na variabilidade do ciclo hidrológico sobre os Estados Unidos. Eles concluíram que, nas escalas anual e sazonal, a precipitação e a evaporação correspondem por cerca de 70-80% da variabilidade.

Outro estudo, realizado por Barbosa e Lakshmi-Kumar (2016), examinou os padrões da vegetação e sua relação com precipitação sobre o nordeste brasileiro. Eles demonstraram que a variabilidade da precipitação emerge como o fator causador dominante da seca agrícola na região. Similarmente, Synodinos *et al.* (2018) simularam o impacto da variabilidade da precipitação interanual sobre os ecossistemas das savanas africanas por meio de um modelo estocástico. Os autores verificaram que os anos secos causaram uma perda de cobertura de árvores, que não pôde ser recuperada durante os anos úmidos devido à forte competição de recursos e ao aumento da frequência de incêndios. Os estudos citados demonstram, de forma

geral, que a variabilidade da precipitação tem efeitos significativos sobre a caracterização hidrológica de uma região (ARNAUD *et al.*, 2002; EMMANUEL *et al.*, 2015, 2017; XIANGHUA *et al.*, 2015). Essa intermitência natural a caracteriza como um fenômeno meteorológico extremamente variável, o que conduz a dificuldades em sua mensuração.

Técnicas de medição de chuva na superfície

Os fenômenos hidrometeorológicos são estudados a partir das observações, experiências e métodos científicos de análise. As observações hidrometeorológicas são avaliações ou medidas de uma ou várias grandezas constituintes desses fenômenos. As observações são denominadas instrumentais quando são realizadas com instrumentos *in situ*, e sensoriais, quando são adquiridas por um observador sem ajuda de instrumentos de medição (YNOUE *et al.*, 2017).

Uma característica de relevância no âmbito da hidrologia é a mensuração da quantidade de chuva. Ela é definida como a altura de lâmina d'água (mm) precipitada e acumulada sobre uma superfície plana de área igual a 1 m², admitindo-se que esse volume não se infiltre, evapore ou esco para fora dessa área (COLLISCHONN; DORNELLES, 2015). Dessa forma, pode-se expressar que uma precipitação de 20 mm, por exemplo, equivale a um volume de 20 litros de água por metro quadrado de projeção de terreno.

Segundo Michaelides *et al.* (2009), a importância da quantificação da chuva possui diversas vertentes. Dentre essas destacam-se a análise de como as mudanças climáticas afetam o fluxo de energia na troposfera e o ciclo hidrológico de forma global, e, em termos regionais, a identificação de alterações nas características das chuvas (intensidade, duração e tipo), sobretudo em eventos extremos, como cheias e estiagens. Sob uma ótica ambiental, o escoamento superficial resultante de uma precipitação líquida pode erodir a superfície do solo e contribuir para o transporte de nutrientes e contaminantes nas zonas costeiras, moldando o meio ambiente. Na dimensão econômica, certas atividades humanas dependem de um prognóstico quantitativo do regime de chuvas como as que envolvem o setor elétrico e o setor agrícola.

Pluviômetros

Os pluviômetros, devido ao seu custo relativamente baixo e a sua simplicidade de instalação e operação, são os aparelhos de medição de precipitações mais comumente utilizados no Brasil

para medições em superfície (COLLISCHONN; DORNELLES, 2015). Há vários modelos de pluviômetros em uso no mundo. No Brasil, o mais difundido é conhecido como *Ville de Paris* (Figura 3.2).



Figura 3.2 – Pluviômetro modelo *Ville de Paris*.

Fonte: ANA (2014).

O *Ville de Paris* consiste em um aro arredondado de captação de área igual a 400 cm², dotado de um cone coletor, coroando um recipiente com capacidade de acúmulo de cerca de 5 litros. Um par de braçadeiras faz a fixação do pluviômetro à estaca a uma altura média de 1,0 m a 1,5 m. A capacidade de acumulação do pluviômetro em termos de altura de precipitação é de 125 mm (STRANGWAYS, 2010).

Em termos funcionais, é um instrumento totalizador que marca a altura total de chuva acumulada num dado período de tempo definido para a frequência das observações, sendo normalmente capazes de armazenar uma chuva ocorrida durante 24 horas, exceto sob situações de excepcional abundância de chuva. É operado por um técnico que mora nas proximidades do aparelho (COLLISCHONN; DORNELLES, 2015). O objetivo principal de uma estação pluviométrica é obter uma série ininterrupta de estimativas de precipitações ao longo dos anos.

Contudo, o volume de chuva presente no pluviômetro depende de uma série de fatores que podem acometer as séries de dados, gerando períodos sem informações ou com falhas nas observações. Geralmente, esses problemas estão relacionados a construção, instalação e manutenção dos pluviômetros e/ou ao operador da estação. Por isso, os dados coletados devem passar por uma análise antes de serem utilizados.

Pluviômetros são instrumentos que possuem limitações. Eles são particularmente sensíveis à exposição, sobretudo aos efeitos ocasionados pelo vento – que ocasiona turbulência nas bordas do equipamento e conseqüentemente erros (cerca de 2% a 10%) na mensuração de chuva – e aos efeitos de evaporação (OMM, 2014), acentuados pela variação de temperatura que se sujeita o pluviômetro ao longo do dia, em especial na época do verão. A baixa frequência de coleta da água precipitada (em geral as medições são realizadas uma vez ao dia) contribui para o agravamento do quadro.

Na Figura 3.3, as linhas sólidas indicam as linhas de fluxo do vento e as linhas tracejadas mostram as trajetórias das partículas de precipitação. O primeiro medidor (1) mostra a maior deformação do campo de vento acima do orifício do pluviômetro e o último (6) a menor. Conseqüentemente, o erro induzido pelo vento para o primeiro medidor é maior do que para o último (OMM, 2014).




Figura 3.3 – Diferentes tipos de pluviômetros e os efeitos do vento sobre eles.

Fonte: Adaptado de OMM (2014).

As medições pontuais de chuva fornecidas pelos pluviômetros servem como fonte primária de dados para análise hidrometeorológica de uma região. No entanto, mesmo a melhor medição da chuva em um ponto é apenas representativa de uma área limitada, cujo tamanho é função da duração do período de acumulação, da homogeneidade fisiográfica da região, da topografia local e do processo de formação da chuva (OMM, 2014). Essas características específicas de cada região geram incertezas inerentes à localidade e ao processo de medição das chuvas.

Com relação ao histórico da rede, os registros podem revelar-se temporalmente heterogêneos quando ocorrem mudanças como alteração do modelo, mudança de local e altura de instalação dos pluviômetros. A heterogeneidade espacial pode ser decorrente do uso de diversos tipos de pluviômetros em uma mesma rede, entretanto, sucede, em especial, da alteração das condições

locais que estão sujeitos os equipamentos, notadamente a altura de objetos vizinhos (KIDD, 2001).

Associado a isso, tem-se o fator humano no processo de monitoramento, o qual pode produzir erros grosseiros de medição, tais como derramamento de água ao transferir os volumes do coletor para a proveta, contagem incorreta do número de provetas, anotação incorreta do valor de precipitação na caderneta e “estimativa” da altura de chuva, motivada pela não realização da leitura no dia/local especificado. À vista disso, os processos de medição devem ser minuciosamente explicitados a fim de compilar um registro histórico compreensivo da estação, com o intuito de garantir dados aptos para estudos climáticos e metodologias de controle de qualidade (OMM, 2014).

O estudo de Lanza e Vuerich (2009) comparou cerca de 30 tipos de pluviômetros com o intuito de identificar o desempenho desses na predição de chuvas de curta duração (~ 1 min) e concluíram que as diferenças nos resultados das medições são significativas. Villarini *et al.*, (2008) utilizou uma rede de 50 pluviômetros implantados em uma área de cerca de 135 km² no sudoeste da Inglaterra para estudar as incertezas temporais e espaciais de amostragem desses instrumentos. Eles identificaram que as incertezas temporais aumentam com o intervalo de amostragem e diminuem com o aumento da área amostrada desde que não haja dependência da orografia local. Grimaldi *et al.* (2018) desenvolveram um pluviômetro com área de captação de 100 m² e analisaram as diferenças entre as medições desse e de pluviômetros tradicionais sob a perspectiva de 26 tipos de eventos de chuva. Os autores evidenciaram grandes discrepâncias (até 40 %) entre os valores mensurados entre eles para chuvas de curta duração (até 15 min) e para altas intensidades de chuva.

Além dessas fontes de erros e das incertezas indicadas nos estudos citados, o número de estações pluviométricas em uso diminuiu consideravelmente nos últimos anos. Conforme apresentado por Becker *et al.* (2013) na Figura 3.4, por exemplo, no conjunto de dados da base *Global Precipitation Climatology Centre* (GPCC), haviam cerca de 10.900 estações utilizáveis em todo o mundo em 1901. O número aumentou de forma constante para um máximo de 49.470 em julho de 1970 e depois caiu para 30.000 em 2005 e posteriormente para apenas cerca de 10.000 em 2012.

Recentemente, Kidd *et al.* (2017) realizaram uma estimativa de quanto da área superficial da Terra é coberta por pluviômetros e concluíram que essa é cerca de $5,93 \times 10^{-10}$ % da superfície

terrestre, o que equivale a uma área inferior a metade de um campo de futebol padrão. Ainda segundo o autor, o número total de pluviômetros é estimado na faixa de 150.000 a 250.000 unidades e essa variação é devida à adoção de diferentes critérios para a contabilização. Entretanto, embora existam muitos medidores, nem todos operaram de forma contínua ou simultaneamente.

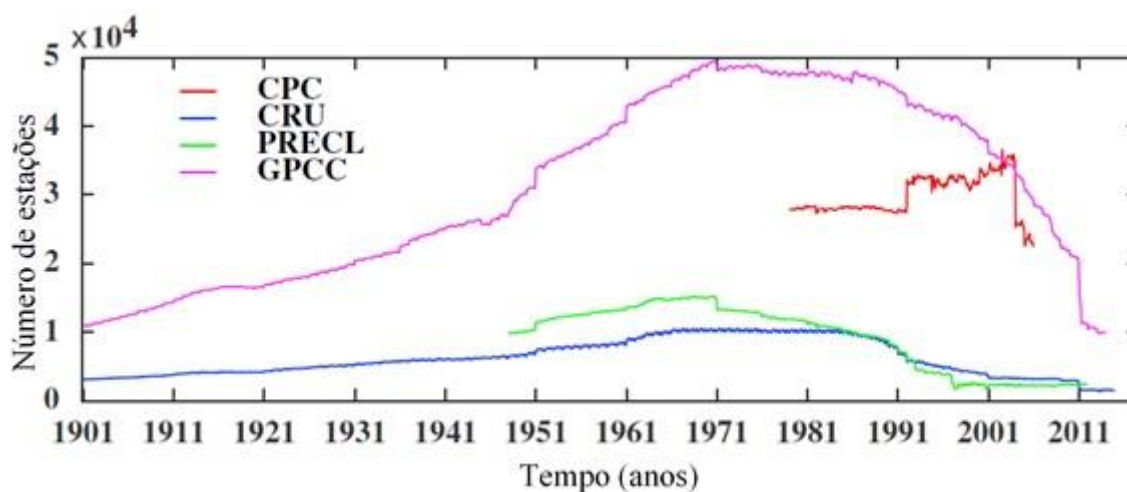


Figura 3.4 – Número de estações pluviométricas nas diferentes bases de dados em função do tempo.

Fonte: Adaptado de Becker *et al.* (2013).

Como o monitoramento da precipitação em grandes bacias exige a instalação de uma densa rede pluviométrica, inclusive em áreas de difícil acesso, as redes de pluviômetros disponíveis, em geral, não satisfazem os requisitos de resolução espacial. Assim, a baixa densidade de postos pluviométricos, somada à falta de qualidade nos dados, geram muitas incertezas na utilização dos dados de precipitação para qualquer aplicação hidrológica.

Ulteriormente, radares e, mais recentemente, satélites são usados para caracterizar e quantificar a distribuição espacial e temporal das chuvas. Em princípio, espera-se que uma integração adequada de todas as três fontes de dados de precipitação regional em redes nacionais (medidores automáticos, radares e satélites) forneça estimativas de chuva superficial suficientemente precisas numa base operacional para uma ampla gama de usuários destes dados.

3.2 Estimativas de precipitação por sensoriamento remoto

O sensoriamento remoto é a ciência de obter informações sobre um objeto através da análise de dados adquiridos por um dispositivo (sensor) que não está em contato direto com o objeto

(remoto). Tal ciência possibilitou a oportunidade de compreender, de forma mais precisa, vários fenômenos recorrentes em nosso planeta.

Os fundamentos dessa ciência baseiam-se principalmente em processos que envolvam a detecção, aquisição e análise (interpretação e extração de dados) da energia em forma de radiação do espectro eletromagnético (Figura 3.5) de objetos e/ou regiões de interesse. Essencialmente, as propriedades desses objetos e/ou uma certa região estão associadas aos seus níveis de energia eletromagnética, que formam um conjunto conhecido por assinatura ou perfil espectral, e fornecem uma maneira de identificar, delinear e os distinguir.

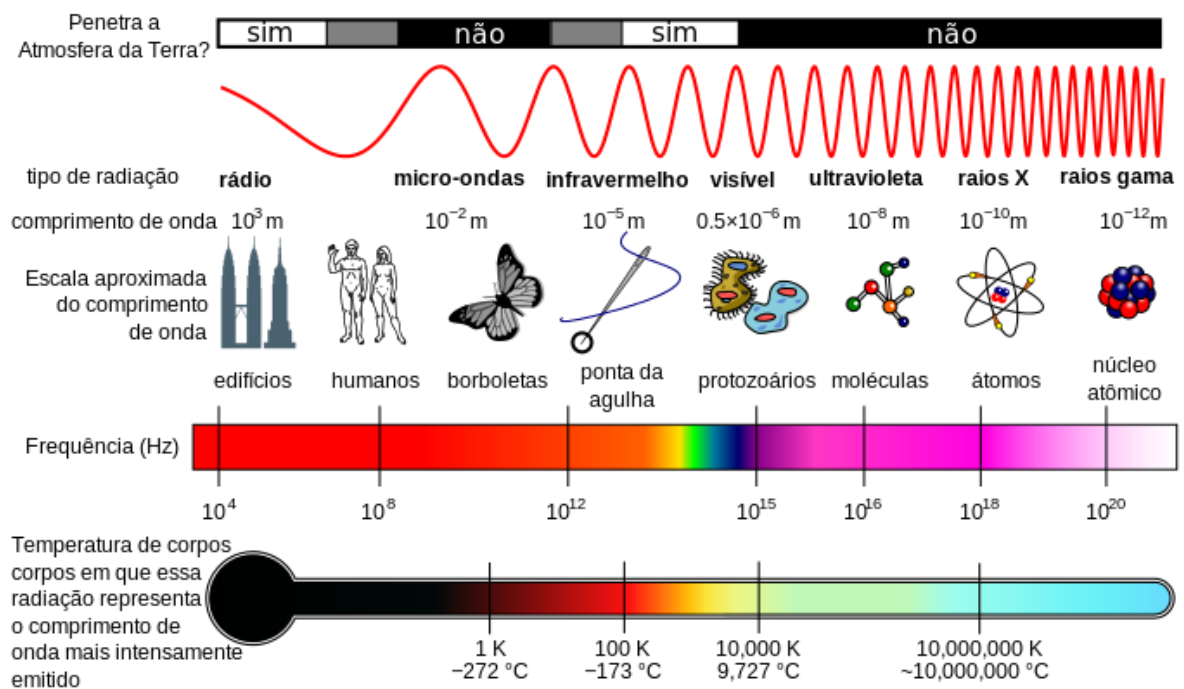


Figura 3.5 – Espectro eletromagnético.

Fonte: Adaptado de Khorram *et al.* (2016).

A quantidade dessa energia eletromagnética dos objetos terrestres resulta das interações entre a radiação eletromagnética e a matéria. Essas interações são determinadas pelas propriedades físico-químicas e biológicas dessas matérias e podem ser categorizadas da seguinte forma: absorção, reflexão, espalhamento, emissão e transmissão da energia eletromagnética. Portanto, a energia eletromagnética refletida e emitida pelos objetos terrestres é a base de dados para todo o processo de sua identificação. Ela permite quantificar a energia espectral refletida e/ou emitida por esses, e assim avaliar suas principais características.

Os primeiros registros da utilização do sensoriamento remoto foram na década de 1840, em que um mapeamento topográfico utilizou fotografias aéreas tiradas de câmeras fixas em balões, capturando características naturais e antrópicas e expondo modificações do uso e ocupação do solo (LAVENDER; LAVANDER, 2015). Segundo Khorram *et al.* (2016), câmeras instaladas em aviões se tornaram uma importante fonte de informação para atividades de reconhecimento e vigilância na Primeira Guerra Mundial. Isso se estendeu para o espaço, embora ainda não em órbita, com os foguetes V-2 adquirindo imagens em meados da década de 1940.

O radar (RADAR do inglês *Radio Detection And Ranging*), inventado pelos ingleses, inicialmente foi projetado para detectar aeronaves, navios de guerra e submarinos. Desde então, o uso das tecnologias de radar expandiu-se significativamente para além das aplicações militares, civis e comerciais. Logo, o uso de radares com foco na observação de variáveis hidrológicas levou a um conjunto de novas descobertas, bem como suas capacidades de monitoramento e previsão, as quais tiveram um grande impacto no campo da hidrologia (HONG; GOURLEY, 2015).

Com o avanço tecnológico, os radares meteorológicos se tornaram uma excelente alternativa para estimar a precipitação, pois são capazes de produzir informações em tempo quase real, com resolução espacial menores que 1 km. Tal como os pluviômetros, as estimativas de precipitação obtidas pelo radar meteorológico são afetadas por múltiplas fontes de erro – notadamente a orientação correta da antena do radar, a atenuação do sinal devida a umidade, neve e obstáculos como montanhas e edificações, a refletividade do radar e a conversão dessa refletividade em intensidade de precipitação (função Z-R) – que devem ser corrigidas para fornecer estimativas de chuva realistas (JIMÉNEZ; COLLISCHONN, 2015).

No Brasil há mais de uma dezena de radares meteorológicos em operação sob supervisão de várias instituições, sendo as principais: o Instituto Nacional de Pesquisas Espaciais (INPE), o Centro de Previsão de Tempo de Estudos Climáticos (CPTEC), o Departamento de Controle e Espaço Aéreo (DECEA), o Instituto de Pesquisas Meteorológicas (IPMET) e o Centro Nacional de monitoramento e Alertas de Desastres Naturais (CEMADEN) (LEAL, 2017). Contudo, a aplicabilidade dos dados monitorados é restrita, pois as informações não são públicas, seus registros históricos são de baixa extensão e a cobertura espacial é insuficiente para representar o regime de chuvas na maioria dos estados brasileiros (CABRAL; SAKURAGI; SILVEIRA, 2016). Nesse contexto, a estimativa de precipitação por satélite (SRE, do inglês *Satellite*

Rainfall Estimates) é uma alternativa para obtenção de dados de precipitação com uma cobertura espacial mais ampla.

Historicamente, desenvolvimentos de satélites para observações terrestres específicas em larga escala espacial começaram em 1959, com o lançamento do satélite *Explorer VII*, projetado para medir a quantidade de calor emitida e refletida pela Terra. Em 1960, foi lançado o satélite meteorológico americano TIROS-1 (do inglês *Television and Infrared Observation Satellite*) que forneceu as primeiras imagens sobre padrões de nuvens terrestres (LAVENDER; LAVENDER, 2015). Desde então, o número de satélites, os dados coletados e as variáveis hidrológicas que podem ser derivadas desses dados, aumentaram significativamente.

Em relação as altitudes de suas órbitas, os satélites meteorológicos podem ser classificados em dois tipos principais: os geoestacionários (GEO) e os em órbita baixa (LEO). Os satélites GEO orbitam a Terra em altitudes que proporcionam ao seu período de translação serem iguais ao período de rotação da Terra. Já os satélites do tipo LEO transladam várias vezes a Terra em único dia em órbitas de baixa altitude (LAVENDER; LAVENDER, 2015). Na Tabela 3.3, estão apresentadas suas principais características, além das vantagens e desvantagens de cada uma das categorias.

Tabela 3.3 – Características típicas de um satélite de cada tipo: GEO e LEO.

Características básicas	Tipos de satélites	
	GEO	LEO
Altitude (km)	~ 35.700	~ 160 a 2000
Velocidade de translação (km/h)	~ 11.068	~ 24.000 a 29.000
Período Orbital	~ 24 h	~ 90 a 120 min
Vantagens	-maior cobertura geográfica; -observação constante de uma mesma região; -excelente resolução temporal (~15 min).	-maiores resoluções espaciais (proximidade); -baixa latência na comunicação.
Desvantagens	-resolução espacial limitada devido a altitude; -observações exclusivamente equatoriais; -limitações de observações nos pólos (paralaxe); -altas latências na comunicação.	-menor cobertura geográfica por passagem; -perda de eventos de curta duração; -necessários muitos satélites para construir uma rede observacional.

Fonte: Adaptado de Capderou (2014).

Cronologicamente, o advento dessa nova possibilidade instituiu diversas agências espaciais, as quais estabeleceram diversos programas meteorológicos inclusive em consórcio entre agências. Assim como os esforços de pesquisa da Administração Nacional da Aeronáutica e Espaço (NASA, do inglês *National Aeronautics and Space Administration*) nas décadas de 1960 e 1970 com o TIROS, NIMBUS e Landsat-1 deram origem aos satélites meteorológicos operacionais da Administração Oceânica e Atmosférica Nacional (NOAA do inglês *National Oceanic and Atmospheric Administration*) conhecidos como *Geostationary Operational Environmental Satellite* (GOES) e *Advanced TIROS* (TIROS-N ou ATN) nos EUA, a Agência Espacial Européia com seu Meteosat na década de 1970 deu origem nos anos 80 à Organização Europeia para a Exploração de Satélites Meteorológicos (EUMETSAT do inglês *European Organisation for the Exploitation of Meteorological Satellites*) e seus programas de satélites geoestacionários METEOSAT e de órbita polar MetOps (PELTON; MADRY; CAMACHO-LARA, 2017).

Segundo Pelton, Madry e Camacho-Lara (2017), em 1977, o Japão lançou seu primeiro satélite meteorológico em órbita geoestacionária para monitorar o Pacífico ocidental e o leste da Ásia. Do mesmo modo, desde 1982, a Organização Indiana de Pesquisa Espacial (ISRO do inglês *Indian Space Research Organization*) instalou satélites meteorológicos geoestacionários INSAT e, em 1994, aproveitando a sua experiência com a série METEOR de satélites em órbita polar, a Federação Russa lançou o seu primeiro satélite geoestacionário (GOMS do inglês *Geostationary Operational Meteorological Satellite*), mais tarde renomeado como Elektra-1. O lançamento em 1988 pela China do *Feng-Yun 1* (FY-1), seu primeiro satélite meteorológico de órbita heliosíncrona, levou em 1997 ao lançamento de seu satélite meteorológico geoestacionário FY-2A. Por meio de um desenvolvimento conjunto do Instituto de Pesquisa Aeroespacial da Coreia (KARI do inglês *Korea Aerospace Research Institute*) e da francesa EADS Astrium, o COMS-1 (do inglês *Communication, Ocean, and Meteorological Satellite*), o último dos satélites meteorológicos geoestacionários foi lançado em junho de 2010. A Tabela 3.4 apresenta uma visão geral dos principais satélites meteorológicos em operação.

Tabela 3.4 – Principais satélites meteorológicos em operação.

Agência espacial	Programa	Missões atuais e futuras relevantes	Principais objetivos
<i>National Aeronautics and Space Administration (NASA)</i>	<i>Earth Observing System (EOS)</i>	Aqua	Observar as nuvens, vapor d'água, precipitação.
NASA e The National Oceanic and Atmospheric Agency's (NOAA)	<i>Suomi National Polar-orbiting Partnership (SNPP)</i>	Suomi-NPP	Meteorologia operacional: química atmosférica e climatologia.
	<i>Joint Polar Satellite System (JPSS)</i>	JPSS-1 (NOAA-20) a JPSS-4	Medir temperatura da atmosfera e do mar; monitorar nuvens, chuvas, gelo e vapor d'água.
NOAA	<i>Geostationary Operational Environmental Satellites (GOES)</i>	GOES-13 a GOES-17	Inspeccionar: tornados, inundações, tempestades de granizo, precipitações de chuva e neve, movimentos de icebergs em lagos e oceanos.
<i>European Space Agency (ESA), e European Organisation for the Exploitation of Meteorological Satellites (EUMETSAT)</i>	<i>EUMETSAT Polar System</i>	MetOp-A MetOp-B MetOp-C	Produzir dados de estimativas de temperatura, perfis de umidade atmosférica e dados para estudos climáticos.
<i>US-Department of Defense (DoD) e NOAA</i>	<i>Defense Meteorological Satellite Program (DMSP)</i>	DMSP-F14 a DMSP-F18	Inspeccionar tipos e alturas de nuvens, temperaturas de corpos d'água, correntes marítimas, características das superfícies do oceano, gelo e neve.
<i>EUMETSAT e ESA</i>	<i>Meteosat Second Generation (MSG)</i>	Meteosat-8 a Meteosat-11	Mensurar a radiação emitida pela Terra, velocidade horizontal do vento e densidade de vapor d'água.
<i>Japan Meteorological Agency (JMA)</i>	<i>Himawari generation</i>	3rd Himawari-8 Himawari-9	Monitorar características das nuvens como: tipo, profundidade ótica, altura e temperatura do topo.
<i>China Meteorological Administration (CMA) e National Remote Sensing Center of China (NRSCC)</i>	<i>Feng-Yun-3</i>	FY-3C a FY-3H	Fornecer sondagens globais de temperatura, umidade tridimensionais da atmosfera e medir parâmetros de nuvens e precipitação.

Fonte: Adaptado de OMM (2019).

Os sensores a bordo dos satélites são os responsáveis pela detecção e registro das ondas eletromagnéticas refletidas e emitidas pelos objetos terrestres. Em função do tipo de produto que produzem, os sensores podem ser classificados em imageadores (*imagers*) e sondadores (*sounders*). Os imageadores geram imagens da superfície observada fornecendo informações sobre a variação espacial da resposta espectral captada. Os sondadores geram sinais digitais (dígitos ou gráficos) que são essenciais para aquisição de informações precisas sobre o comportamento espectral dos objetos (LIU *et al.*, 2012). Exemplos dos sensores atuais utilizados para gerar estimativas de precipitação estão descritos na Tabela 3.5.

Tabela 3.5 – Principais sensores imageadores e sondadores utilizados pelos produtos de satélite.

Tipo de sensor	Nome	Acrônimo
Sondador	<i>Advanced Microwave Sounding Unit</i>	AMSU
	<i>High-resolution Infra Red Sounder</i>	HIRS
	<i>Microwave Humidity Sounding</i>	MHS
	<i>Infra Red Atmospheric Sounder</i>	IRAS
	<i>Micro-Wave Temperature Sounder</i>	MWTS
	<i>GOES Sounder</i>	G-SOUNDER
Imageador	<i>Advanced Very High Resolution Radiometer</i>	AVHRR
	<i>Micro-Wave Radiation Imager</i>	MWRI
	<i>Visible and Infra-Red Radiometer</i>	VIRR
	<i>GOES Imager</i>	G-IMAGER
	<i>Advanced Baseline Imager</i>	ABI
	<i>Spinning Enhanced Visible Infra-Red Imager</i>	SEVIRI
Imageador e sondador	<i>Advanced Himawari Imager</i>	AHI
	<i>Special Sensor Microwave - Imager/Sounder</i>	SSMIS

Fonte: Adaptado de OMM (2019).

Também é possível, em função da fonte de energia utilizada, distinguir duas categorias para detecção das ondas eletromagnéticas, as que utilizam sensores passivos e ativos. Os sensores passivos, a categoria mundialmente predominante em operação, registra as ondas dos objetos e/ou regiões. Exemplos nessa categoria são os sensores “térmicos” que atuam na banda do infravermelho, os sensores “ópticos” que são capazes de identificar as ondas na banda da luz visível e os radiômetros de micro-ondas passivas (LAVENDER; LAVENDER, 2015). Em contraste, os sensores ativos geram e emitem as ondas sobre os alvos de interesse e, em seguida, detectam e aferem a intensidade e o atraso dos sinais de retorno. Segundo Khorram *et al.* (2016), à medida que as plataformas ativas emitem um sinal, elas consomem mais energia do que os sensores passivos e, com frequência, só são acionados quando elas precisam registrar os dados, ou seja, elas não coletam rotineiramente conjuntos de dados globais completos. Os radares meteorológicos são os representantes dessa categoria.

A partir das radiações captadas pelos sensores, as agências espaciais criaram técnicas (algoritmos) capazes de converterem essas informações em estimativas de precipitação. Logo, o registro de dados gerados é armazenado em formato digital em arquivos do tipo *raster*. O *raster* é uma matriz bidimensional (grade ou “grid”) composta de *pixels* que armazenam as suas coordenadas geográficas, dimensões (escala espacial) e os valores da variável hidrológica em

estudo (KHORRAM *et al.*, 2016). No caso da variável precipitação, esse *raster* é comumente mencionado na literatura como produto de precipitação por satélite e/ou campo de chuva.

O desenvolvimento desses algoritmos respalda-se em extrair informações relevantes de bandas específicas do espectro eletromagnético. Cada uma possui características pertinentes acerca da formação de precipitação. As principais bandas utilizadas pelos algoritmos podem ser categorizadas em três classes predominantes. São elas:

- banda visível (faixa de comprimento de onda (λ) de ~ 380 a 750 nm);
- banda infravermelha térmica ($0,75 \mu\text{m} < \lambda \leq 1$ mm); e
- banda de micro-ondas (1 mm $< \lambda \leq 30$ cm).

Até o presente momento, as radiações de outras faixas do espectro eletromagnético são inviáveis de se utilizar para estimativas de precipitação, pois tais ondas nessas faixas são bloqueadas (opacas) pela atmosfera ou insensíveis as propriedades dos hidrometeoros (TAPIADOR, 2018).

3.2.1 Algoritmos do espectro visível e do infravermelho

Os sensores baseados em radiações visíveis (Vis) captam a luz solar refletida pelos topos das nuvens. Segundo o fundamento dos seus algoritmos, quanto mais “clara/branca” a nuvem for (maior albedo), mais espessa ela é, e a essa espessura é associada uma maior probabilidade de chuva em superfície. Além dessa relação, as imagens Vis fornecem informações sobre a composição e tipos das nuvens. A composição está associada diretamente ao brilho das nuvens, visto que as nuvens mais brancas tendem a ser formadas como uma densidade maior de cristais de gelo do que gotas de água. Os tipos estão associados a textura das imagens Vis, em que nuvens do tipo *stratus* aparecem tipicamente suaves, enquanto nuvens convectivas aparentam mais irregulares (LEVIZZANI *et al.*, 2001). A maior deficiência nesse método é que, além de requererem um processamento cuidadoso para levar em conta as mudanças nos ângulos dos raios solares sobre as nuvens, as imagens Vis só estão disponíveis durante o dia, o que inviabiliza a cobertura temporal desses sensores. Devido a essa grave deficiência, as técnicas preliminares que utilizaram somente dados de sensores Vis ficaram restritas a estudos de caso, não sendo aplicadas em escala global (KIDD; LEVIZZANI, 2011).

Os algoritmos que utilizam o espectro IV baseiam-se na temperatura das ondas emitidas pelo topo das nuvens. À medida que as nuvens ascendem na troposfera, suas temperaturas decrescem

a uma taxa de $6,5^{\circ}\text{C}/\text{km}$ (YNOUE *et al.*, 2017). Logo, nuvens muito elevadas possuem, em média, seu topo mais frio, como as nuvens do tipo *cumulonimbus*. Em situações similares, nuvens com essas características tendem a ser associadas a chuvas mais intensas na superfície. Portanto, os algoritmos IV inferem estimativas de precipitação a partir das temperaturas do topo das nuvens. No entanto, os sensores IV podem identificar nuvens frias e altas, como a *cirrus*, as quais não produzem chuva. O mesmo lapso ocorre com a não identificação de nuvens estratiformes (nuvens com topos quentes), que podem produzir volumes significativos de chuva. Para essas situações, os algoritmos IV tendem a superestimar e subestimar a precipitação em superfície, respectivamente (TAPIADOR *et al.*, 2012).

Dentre os algoritmos mais relevantes que utilizam informações dos sensores IV pode-se citar o *Geostationary Operational Environmental Satellites (GOES) Precipitation Index (GPI)* de Arkin, Joyce e Janowiak (1994). O GPI associa uma taxa constante de chuva de 3 mm/h para topos de nuvens identificadas com temperaturas abaixo de 235 K ($< -38^{\circ}\text{C}$) em escala temporal mensal e espacial de $2,5^{\circ} \times 2,5^{\circ}$. Apesar de simples, a relação utilizada pelo GPI é aplicável em sistemas convectivos, geralmente limitando a técnica as latitudes 40°N - 40°S , onde a maioria dos sistemas precipitantes pode ser considerada dessa natureza (KIDD; HUFFMAN, 2011). O algoritmo *Auto-Estimator (AE)* utiliza o comprimento de onda de $10,7 \mu\text{m}$ do GOES para calcular os valores de precipitação em tempo real com base em uma regressão com função potência (VICENTE; SCOFIELD; MENZEL, 1998). Essa regressão é concebida por uma análise estatística entre as estimativas de precipitação instantânea, derivadas de radar em superfície, e as temperaturas do topo da nuvem derivadas de satélite. Algoritmos similares que realizam regressão através dados de sensores IV são a revisão do próprio AE (VICENTE; DAVENPORT; SCOFIELD, 2002) e o *Hydro-Estimator (HE)* (KULIGOWSKI, 2002). Ainda assim, as relações entre a temperatura dos topos das nuvens e precipitação em superfície são fisicamente indiretas.

Dados obtidos por meio das radiações da banda do infravermelho próximo (IV_P), possibilitaram avanços na compreensão sobre a microfísica das nuvens. As ondas refletidas/emitidas de comprimentos de ondas iguais a 1,6, 2,1 e $3,9 \mu\text{m}$ fornecem estimativas sobre a dimensão e fase (líquida ou sólida) das partículas do topo das nuvens (KIDD; LEVIZZANI; LAVIOLA, 2010). Não obstante, na prática, com a evolução rápida dos sensores Vis e IV, os algoritmos utilizaram dados de ambas bandas para estimar precipitação em superfície. O algoritmo *Clouds-Aerosols-Precipitation Satellite Analysis Tool (CAPSAT)*

(LENSKY; ROSENFELD, 2008) classifica as imagens Vis/IV usando tabelas adaptadas às condições “microfísica do dia” e “microfísica da noite”, permitindo a classificação de eventos baseado na microfísica da nuvem, o que é útil para o delineamento da área de chuva. Ba e Gruber (2001) utilizaram informações conjuntas dos sensores Vis, IV_P, vapor d’água e IV para extrair informações das dimensões das nuvens precipitantes. Posteriormente, derivaram a precipitação aplicando correções segundo o tipo de nuvem e regimes de precipitação. Tal técnica foi nomeada *GOES Multispectral Rainfall Algorithm* (GMSRA). Apesar do grande número de técnicas de sensores Vis/IV desenvolvidas, inclusive bastante promissoras (TAPIADOR *et al.*, 2017; VARMA, 2018) especialmente sobre aplicações em terra, todas têm suas limitações. A principal desvantagem é que todas essas técnicas têm que inferir a precipitação em superfície a partir da temperatura ou brilho do topo da nuvem.

3.2.2 Algoritmos do espectro micro-ondas

Enquanto isso, foi estabelecido já em meados da década de 1970, que as imagens de micro-ondas passivas podiam fornecer uma avaliação útil da precipitação sobre os oceanos (KIDD, 2001). Os sensores passivos que captam as radiações de micro-ondas (MO) possuem uma relação mais direta com a precipitação em superfície. Ondas dessa janela do espectro possuem a capacidade de penetrar nas nuvens e são sensíveis a características físicas do vapor d’água, particulados e hidrometeoros presentes em sua composição. Dependendo do comprimento de onda das MO observadas, o sinal captado pelo radiômetro é predominantemente devido aos mecanismos de *emissão* ou dispersão dessa radiação (TAPIADOR *et al.*, 2012). O processo de emissão está associado às observações sobre o oceano, o qual mantém uma emissividade relativamente baixa e uniforme ($\epsilon \sim 0,4-0,5$). Porém, perante a um evento precipitante, as gotas de chuva emitem micro-ondas, aumentando a intensidade do sinal de radiação captada pelos sensores que operam em baixa frequência (< 20 GHz). A essa diferença é associada uma taxa de chuva presente na coluna atmosférica (KIDD, 2001). Um algoritmo baseado nessa premissa foi desenvolvido por Ferraro (1997), o qual utiliza dados do sensor SSM/I para realizar estimativas de precipitação.

Sobre a superfície terrestre, como a emissividade dessa é elevada ($\epsilon \sim 0,9$) e varia conforme a sua cobertura superficial, torna-se mais difícil discriminar se as ondas captadas pelo sensor são advindas da atmosfera ou não. Portanto, o processo de dispersão das ondas com frequência acima de 60 GHz é utilizado. Nesse procedimento, as ondas advindas da superfície são espalhadas pelas partículas de gelo presentes na atmosfera, reduzindo a radiação captada pelo

sensor sobre uma dada região. Esse decréscimo no sinal é relacionado à densidade de partículas de gelo presentes nas nuvens (TAPIADOR *et al.*, 2012). Embora os algoritmos baseados em emissão fornecem taxas de precipitação dentro da coluna atmosférica, e os algoritmos baseados em dispersão fornecem uma quantificação das partículas de gelo das nuvens, ambos não fornecem a precipitação real sobre a superfície. O algoritmo operacional *Goddard Profiling* (GPROF), proposto por Kummerow, Olson e Giglio (1996), utiliza uma estratégia físico-probabilística para gerar estimativas de precipitação dos dados de sensores MO por meio da modelagem de nuvens. O algoritmo é baseado em abordagem bayesiana que começa estabelecendo um extenso banco de dados de perfis de hidrometeoros e suas respectivas temperaturas de brilho. Esse banco de dados é calculado a partir de modelos de classificação de nuvem. Com isso, o GPROF concebe a intensidade instantânea e a composição da estrutura vertical da chuva usando valores de frequências variadas que observam diferentes profundidades dentro da coluna atmosférica. Um aprimoramento desse algoritmo foi utilizado pelo imageador de micro-ondas a bordo do satélite TRMM (KUMMEROW *et al.*, 2001). Atualmente, a sua versão operacional mais recente é utilizada pelo imageador do satélite GPM (KUMMEROW *et al.*, 2015).

Devido à interação das ondas de micro-ondas com hidrometeoros, as técnicas de estimativa de precipitação baseadas em MO oferecem uma estimativa mais direta da precipitação do que as técnicas de Vis/IV. Contrariamente aos sensores Vis/IV, os MO estão a bordo somente de satélites do tipo LEO atualmente, o que impossibilita a observação constante de uma mesma região. Além do mais, os comprimentos de onda nessa faixa são relativamente maiores do que as outras radiações utilizadas para mensurar a precipitação, o que limita a resolução espacial observada pelo sensor (VARMA, 2018). Naturalmente, outros algoritmos foram propostos de forma a combinarem os dados de sensores distintos para explorar os benefícios que cada um deles oferece. Essas técnicas são denominadas de algoritmos multissensoriais ou multiespectrais.

3.2.3 Algoritmos multiespectrais

A ideia central das técnicas multissensoriais foi associar a alta resolução temporal (~ 15 min) e espacial (~ 4 km) dos dados de sensores visíveis-infravermelhos (Vis/IV) a bordo dos satélites GEO com as estimativas mais diretas proporcionadas pelas micro-ondas (MO) a bordo de satélites LEO. Esse procedimento possibilitou a gênese dos produtos estado-da-arte de precipitação por satélite (TAPIADOR *et al.*, 2017).

Existem vários algoritmos que utilizam a abordagem multiespectral, e, com o avanço tecnológico dos sensores, há uma certa tendência dos produtores de dados nessa linha (SUN *et al.*, 2018). Dentre esses, destaca-se o produto PERSIANN, que usa uma rede neural para classificação de imagens infravermelhas fornecidas por satélites geoestacionários para calcular estimativas de intensidade de precipitação em superfície. Em seguida, o processo foi ampliado para incluir o uso de imagens do espectro visível obtidas durante o dia. Posteriormente, foi criado um recurso de treinamento adaptativo que facilita a atualização dos parâmetros da rede neural utilizando dados de sensores passivos de MO disponíveis (ASHOURI *et al.*, 2015).

Nessa linha, a NASA produz o produto TMPA nos seguintes estágios: (i) as estimativas de precipitação disponíveis de vários sensores MO são calibradas e combinadas; (ii) concebe-se as estimativas de precipitação de IV através da precipitação de MO calibrada; (iii) ambas as estimativas MO e IV são combinadas; e (iv) dados de pluviômetros são incorporados ao produto final (HUFFMAN *et al.*, 2007; KIRSCHBAUM *et al.*, 2017).

Já o produto CMORPH utiliza qualquer estimativa de precipitação disponível derivada exclusivamente de observações de sensores MO instalados em satélites LEO, cujas características são transportadas por meio da propagação de vetores de movimento que são obtidos inteiramente a partir de informações IV em satélites GEO. A técnica, portanto, não é um algoritmo de estimativa de precipitação em si, mas um meio pelo qual as estimativas de precipitação de micro-ondas dos algoritmos existentes podem ser combinadas (XIE *et al.*, 2017).

Além desses, produtos emergentes como o *Global Satellite Mapping of Precipitation* (GSMaP) (KUBOTA *et al.*, 2007), o *Climate Hazards Infrared Precipitation with Stations* (CHIRPS) (FUNK *et al.*, 2015) e principalmente, o *Integrated Multi-satellitE Retrievals for GPM* (IMERG) (HOU *et al.*, 2014) fornecerão a nova base de dados de precipitação da constelação de satélites com os sensores de última geração. De forma sumária, a Tabela 3.6 apresenta os principais produtos multissensoriais atuais citados e suas características mais relevantes.

Tabela 3.6 – Resumo dos principais produtos de precipitação por satélite multissensorial e seus atributos.

Acrônimo	Fonte de dados primária	Cobertura espacial	Resoluções dos produtos	Histórico de dados
TMPA	GEO-IV LEO-MO	50°N-50°S	3 h ~ 25 km Diária ~ 25 km Mensal ~ 25 km	1998-presente
IMERG	GEO-IV LEO-MO	60°N-60°S	30 min ~ 10 km Mensal ~ 25 km	2014-presente
CMORPH	GEO-IV LEO-MO	60°N-60°S	30 min ~ 8 km 3 h ~ 25 km Diária ~ 25 km	2002-presente
PERSIANN	GEO-Vis/IV LEO-Vis/IV	60°N-60°S	1 h ~ 25 km 3 h ~ 25 km Diária ~ 25 km Mensal ~ 25 km	2000-presente
GSMaP	GEO-IV LEO-MO	60°N-60°S	1 h ~ 10 km Diária ~ 25 km	1998-presente
CHIRPS	GEO-IV	50°N-50°S	Diária ~ 5/25 km Mensal ~ 25 km	1981-presente

Fonte: Adaptado de Ferraro *et al.* (2018).

Contudo, as técnicas citadas conduzem à elaboração de algoritmos complexos, à exigência significativa de processamento de dados, são fundamentadas em transformações indiretas de radiações em precipitação e não conseguem representar por completo o fenômeno físico em si (TAPIADOR *et al.*, 2017). Além disso, Ferraro *et al.* (2018) mostrou que não há diferenças alarmantes entre os algoritmos que utilizam sensores individuais para os algoritmos multissensoriais. Em síntese, do mesmo modo que os pluviômetros e os radares, os produtos de precipitação por satélite possuem várias fontes de erro, devido à natureza dos produtos, a quantificação desses é problemática. Entender a proveniência dos dados de entrada e o esquema de processamento é crucial para identificar as particularidades de cada produto de precipitação e para assegurar que as conclusões corretas sobre o desempenho do mesmo sejam fornecidas.

3.3 Incertezas nas estimativas de precipitação por satélites

Conforme já citado, a energia eletromagnética refletida, emitida e espalhada pelas precipitações é a base de dados para todo o processo de sua identificação em sensoriamento remoto. Ela permite quantificar a energia espectral refletida e/ou emitida pelos hidrometeoros, e assim avaliar suas principais características. Os produtos de precipitação por satélite utilizam de sensores a bordo desses satélites para estimar as precipitações. Nesse contexto, essas técnicas possuem incertezas associadas aos tipos de sensores que são utilizados.

O problema da incerteza surge quando mais de um instrumento de mensuração (fonte de dados) observa o mesmo fenômeno de precipitação, e uma das fontes é considerada mais confiável (pluviômetros e/ou radares meteorológicos) do que a outra (satélites). A identificação das diferenças entre as estimativas de precipitação, obtidos por pluviômetros e por meio de sensores remotos, é o primeiro passo para uma análise dessas incertezas. Não há, entretanto, distinção acerca da fonte do erro. Caracterizá-las e, se possível, minimizá-las é essencial para aplicações dessas informações em estudos hidrometeorológicos.

Fundamentalmente tem-se dois tipos de incertezas associadas aos processos de medição que podem ser categorizadas em: aleatórias (intrínsecas) e sistemáticas. Segundo Naghettini e Pinto (2007), as primeiras advêm da incapacidade dos instrumentos e/ou do operador produzir resultados puramente idênticos por meio da repetição de um experimento sob as mesmas condições. Portanto, tais medidas trazem consigo as imprecisões das leituras e medições, ou seja, as oscilações naturais geradas nos resultados obtidos. As incertezas sistemáticas (epistêmicas) podem ter fontes diversas como em mudanças na técnica de medição empregada, em calibrações incorretas de instrumentos de medição ou nos processos de coleta, transmissão e processamento dos dados. Portanto, decorrem da insuficiência ou ausência de compreensão e/ou informação sobre todos os processos físicos que governam o fenômeno modelado produzindo um viés nos resultados das observações (SILVA, 2015). A presente pesquisa concentra-se em avaliar as incertezas da última categoria.

3.3.1 Divergências na escala temporal

As principais diferenças entre as técnicas de mensuração de chuvas estão relacionadas a resolução temporal, espacial e a acurácia dos instrumentos de medição. Para tal, é necessário compará-las em uma mesma escala temporal e espacial. De acordo com Kidd e Huffman (2011), na escala temporal, as divergências provêm dos intervalos de tempo que o satélite observa a região e frequência da ocorrência de chuvas na mesma. Chuvas do tipo convectivas tendem a ser de pequena duração e até mesmo sensores a bordo de satélites GEO podem não registrar esses eventos, por terem uma frequência de observação menor (> 30 min) que a duração do evento. Ainda segundo os autores, para essas situações, os sensores a bordo de satélites do tipo LEO, raramente observam esses eventos, em fato devido às plataformas LEO possuírem altas velocidades translacionais (~ 25.000 km/h) (Tabela 3.3), acarretando em passagens muito rápidas sobre uma determinada região. Portanto, os satélites observam uma “fotografia” instantânea do sistema atmosférico, porém não conseguem monitorá-lo de forma constante.

Outra incompatibilidade temporal advém da comparação entre dados de satélite e das medidas em superfície, especificamente pluviômetros (REIS; RENNÓ; LOPES, 2017). A título de exemplo, nos pluviômetros da rede hidrometeorológica sob o domínio da Agência Nacional das Águas (ANA), a leitura é realizada uma vez por dia por um observador, que anota o valor lido na caderneta “Leitura diária de chuva” sempre às 7:00h da manhã no horário local (ANA, 2014). Apesar da precipitação ser anotada no mesmo dia da leitura, a maioria das horas monitoradas estão compreendidas no dia anterior. Portanto, os pluviômetros fornecem um valor acumulado de precipitação entre leituras. Já os produtos de satélite são fornecidos em diversas escalas temporais, variando entre 1h até a escala mensal, possibilitando ao usuário muitas opções de escolha para as mais diversas aplicações. Uma escala temporal muito comum entre vários produtos de satélite e de aplicação considerável na literatura recente é a de 3h (BECK *et al.*, 2019). Logo, os produtos nessa escala fornecem estimativas de chuva a cada 3h – produzindo 8 estimativas de precipitação (arquivos do tipo *raster*) por dia – de forma global e/ou regional dentro do seu respectivo domínio (latitudes e longitudes).

Além disso, o usuário dos produtos de satélite deve atentar-se para a correspondência do horário de registro da chuva pelo satélite com o horário local da chuva sobre a região em estudo. A grande maioria dos produtos de satélite são registrados no sistema padronizado de tempo “Tempo Universal Coordenado” (UTC do inglês *Universal Time Coordinated*) (KIRSCHBAUM *et al.*, 2017). Elucidando, chuvas que ocorreram no dia 14/11/2018 às 21:00 no seu horário local em Brasília são registradas pelos produtos de satélite às 00:00 do dia 15/11/2018, gerando uma defasagem de 3h entre os dados dos pluviômetros e dos satélites. Similarmente, o usuário deve sopesar as unidades de medida de precipitação fornecidas pelos produtos de satélites, pois alguns produtos como o IMERG e TMPA fornecem intensidades de precipitação em mm/h, já outros produtos como o CMORPH e o PERSIANN fornecem o acumulado de precipitação em um determinado intervalo de tempo (HOU *et al.*, 2014). Essas características dos produtos são extremamente relevantes para que os usuários realizem as manipulações de dados necessárias de forma adequada, nomeadamente quando esses deverão ser “agregados” para análise diária, semanal, decenal e/ou mensal.

3.3.2 Divergências na escala espacial

A comparação na escala espacial entre os dados de pluviômetros e os dados de satélites é de maior complexidade e de discussão mais abrangente na literatura. As divergências surgem devido aos pluviômetros, fundamentalmente, realizarem medições puntiformes de precipitação

e os satélites fornecem uma precipitação média superficial (MAP, do inglês *mean areal precipitation*) sobre uma determinada região. Logo, ambas as mensurações são produzidas em escalas espaciais – e dependendo da resolução espacial dos satélites – severamente distintas (PLOUFFE; ROBERTSON; CHANDRAPALA, 2015).

Conforme já mencionado, a área de captação de um pluviômetro é de 400 cm², já uma escala espacial típica dos *pixels* de satélite é a de 0,25° x 0,25°, o que corresponde a aproximadamente 625 km². Portanto, enquanto os SRE captam precipitações num determinado *pixel*, pluviômetros internos a esse *pixel* podem não captar esse evento. De forma similar, eventos distintos ocorrendo no mesmo *pixel* são registrados pelos satélites como único, desconsiderando a variabilidade da chuva. Do contrário, eventos podem ser de tão pouca extensão espacial que a resolução dos sensores é insensível a esses. Ademais, quando o núcleo precipitante da nuvem está diretamente acima do pluviômetro, o mesmo pode registrar intensidades diferentes dos SRE (TAPIADOR, 2018).

Portanto, a espacialização da precipitação pode ser considerada como dois problemas em um, uma vez que tanto a identificação da ocorrência quanto a quantificação dos volumes precipitados devem ser avaliados. Porém, ela torna-se necessária, já que a amostragem dessa variável, por mecanismos tradicionais, nunca é feita em pontos muito próximos entre si, em razão, por exemplo, da limitação econômica e dificuldades na instalação dos instrumentos de medição (YAMAMOTO; LANDIM, 2013).

Sucintamente, três abordagens podem ser consideradas na comparação dessas mensurações na escala espacial: i) comparação direta entre os dados do pluviômetro e do *pixel* de satélite que contém o pluviômetro; ii) interpolar espacialmente a chuva registrada pelo pluviômetro em um *grid* compatível com a resolução espacial dos *pixels* de satélite, processo conhecido como “*upsampling*” (ponto → *pixel*) (HUANG; CHANG; LIU, 2018; PALOMINO-ÁNGEL; ANAYA-ACEVEDO; BOTERO, 2019) ou; iii) reamostrar os dados de satélite com o intuito que os campos de chuva sejam representativos sobre o pluviômetro, ou seja, adequar uma chuva superficial média (*pixel*) em uma chuva puntiforme (pluviômetro). Essa última é conhecida por “*downsampling*”, “*resampling*” ou ainda interpolação dos produtos de satélite sobre os pluviômetros (*pixel* → ponto) (UDDIN *et al.*, 2008; ULLOA *et al.*, 2017; ZHANG *et al.*, 2018).

A interpolação espacial é um processo matemático projetado para predizer o valor em um ponto ou em uma região onde o valor é desconhecido com base em dados amostrais conhecidos

(YAMAMOTO; LANDIM, 2013). Baseando-se no princípio matemático utilizado, uma forma simples de divisão entre os métodos pode ser em modelos determinísticos e modelos estocásticos (também conhecidos por probabilísticos ou geoestatísticos). Os modelos determinísticos podem ser agrupados em dois enfoques: local e global. Essa subdivisão reside na suposição implícita de que para a caracterização do fenômeno em estudo predominam os efeitos puramente locais e a variação em larga escala, respectivamente (PLOUFFE; ROBERTSON; CHANDRAPALA, 2015).

Os modelos determinísticos utilizam critérios geométricos considerando as distâncias euclidianas entre amostras e não avaliam a incerteza acerca dos resultados. Já os modelos estocásticos consideram os valores coletados provenientes de processos aleatórios e são capazes de quantificar a incerteza associada ao estimador (YAMAMOTO; LANDIM, 2013). Respaldoando-se nesses fundamentos, várias técnicas de interpolação foram criadas e algumas são citadas na Tabela 3.7.

Tabela 3.7 – Algumas técnicas de interpolação espacial.

Interpolação espacial		
Determinística		Estocástica
Local	Global	
Média simples	Polinomial global ou	Krigagem ordinária
Média ponderada	superfícies de tendência	Krigagem simples
Método das isoietas		Krigagem universal
Polígonos de Thiessen		Co-krigagem
Ponderação pelo inverso da distância		

Fonte: Adaptado de Chen e Guo (2017).

Estudos que envolvem técnicas de interpolação concentram-se principalmente nas duas seguintes abordagens: (i) interpolar os dados em uma região usando diferentes técnicas de interpolação, em uma tentativa de comparar a precisão das técnicas utilizadas e analisar as variações espaciais e temporais de elementos meteorológicos na região; e (ii) aumentar a precisão da interpolação melhorando as técnicas interpoladoras existentes. Entretanto, as técnicas aprimoradas são geralmente adequadas apenas para a área de estudo específica e não para outras regiões (CHEN; GUO, 2017).

Plouffe, Robertson e Chandrapala (2015) apresentaram uma comparação entre diversos estudos sobre a utilização dos mesmos interpoladores de chuva sob diferentes regiões e circunstâncias.

Segundo os autores, estudos prévios da mesma natureza obtiveram diferentes conclusões em relação à técnica mais efetiva de interpolação. Estudos similares como os de Oke, Frost e Beesley (2009) e Shi *et al.* (2015) mostraram que no âmbito geral, não há um consenso sobre a indicação de um interpolador otimizado, especialmente em regiões tropicais onde os padrões de precipitação são extremamente variáveis.

Dessa forma, apresentadas as incompatibilidades entre os dados dos pluviômetros e dos satélites, devidas às escalas temporal e espacial de ambos, a maioria dos estudos, primordialmente, não aplica de forma direta os produtos de satélite sobre uma determinada região. Previamente é realizada uma validação dos produtos escolhidos em diversas escalas temporais e espaciais. Essa metodologia é realizada pelo cálculo de estatísticas de chuva que podem ser divididas em: estatísticas de ocorrência (categóricas ou qualitativas) e estatísticas quantitativas (WILKS, 2011).

Referenciado-se por Ebert (2007) e Wilks (2011), as estatísticas categóricas estão associadas ao desempenho do satélite em identificar eventos chuvosos e sem chuva dado um limiar (*threshold*) pré-definido ou por classes de chuvas. Já as estatísticas quantitativas (métricas de erro) estão associadas a acurácia do produto de satélite que, por definição, representa a proximidade entre o valor dos dados de satélite (estimativas de precipitação) e o valor dos dados dos pluviômetros (precipitação de referência). Os estudos mais recentes (BECK *et al.*, 2017, 2019; QUIRINO *et al.*, 2017; ROZANTE *et al.*, 2018) se concentram em avaliar um ou mais produtos de satélite sobre uma determinada região visando identificar qual o produto que apresenta, em média, um melhor desempenho.

Os dados dos produtos de satélite TRMM 3B42: v6, v7 e RT, CMORPH, *Hydro-Estimator* (HYDRO) e o algoritmo *Combined Scheme* (CoSch) foram comparados com os de uma densa rede pluviométrica num período de cerca de dois anos (dezembro/2008-novembro/2010) sobre a América do Sul por Salio *et al.* (2015). O estudo demonstrou que os algoritmos “combinados” (*blended*) que incluem observações de micro-ondas e observações de superfície (3B42v6, v7 e CoSch) apresentaram desempenho superior. O CMORPH apresentou superestimava, principalmente para valores extremos em áreas planas. Já as estimativas baseadas em parâmetros associados a imagens de infravermelho (HYDRO) subestimaram as precipitações ao sul da latitude 20°-S e superestimaram as precipitações tropicais ao norte. A inclusão de dados de superfície nos algoritmos dos produtos aprimora de forma geral as estimativas de

precipitação nas escalas mensal (3B42 V7 e V6) e diária (CoSch). As estimativas que incluem observações de sensores micro-ondas mostraram uma forte tendência de superestimar valores extremos de precipitação acima de 70 mm. Este efeito é fortemente evidente no norte e centro da Argentina e no sul do Brasil (SALIO *et al.*, 2015).

Soares, Paz e Picilli (2016) analisaram o produto 3B42_v7 do satélite TRMM sobre o estado da Paraíba. As análises foram realizadas tanto ao nível local de cada pluviômetro (comparação direta sem interpolação), quanto agregada espacialmente, segundo as mesorregiões Mata, Agreste, Borborema e Sertão, considerando chuvas diárias, de três dias, de sete dias e mensais. Foi obtida uma maior concordância (r diário = 0,89 e erro médio absoluto mensal = 16 mm) para regiões com menores totais precipitados (região do Sertão). Os dados do TRMM subestimaram valores observados nos locais de maior índice pluviométrico (viés mensal de -24 mm na região da Mata) e superestimaram nos locais de menor índice pluviométrico (viés mensal de +13 mm no Sertão e +11 mm na Borborema).

Abera, Brocca e Rigon (2016) realizaram uma avaliação comparativa de diferentes produtos de estimativa de precipitação por satélite (3B42V7, CMORPH, TAMSAT, SM2R-CCI e CFSR) pela complexa bacia do Alto Nilo Azul (África). Foram encontradas diferenças da ordem de 2.700 mm em chuvas médias anuais entre os produtos escolhidos. Considerando o coeficiente de correlação, o viés e o RMSE os produtos CMORPH, TAMSAT e SM2R-CCI obtiveram os melhores resultados. Também foram realizadas análises sob diferentes intensidades de precipitação e o TAMSAT identificou melhor os dias secos. Em contrapartida o SM2R-CCI identificou melhor os dias chuvosos (na classe de 10-20mm).

Nguyen *et al.* (2018) forneceu uma visão geral dos algoritmos disponíveis da família de produtos PERSIANN e suas diferenças. Ademais, apresentaram uma avaliação desses produtos (PERSIANN, PERSIANN-CCS e PERSIANN-CDR) sobre os Estados Unidos em diferentes escalas espaciais e temporais, usando os dados das estações do CPC como referência durante o período de 2003 a 2015. Baseando-se nos resultados encontrados, os autores afirmam que o PERSIANN-CCS é indicado para estudos de previsão de inundações devido aos elevados coeficientes de correlação apresentados, à baixa latência de produção (~1h) e a fina escala espacial ($0.04^\circ \times 0.04^\circ$) do produto. Entretanto, o produto PERSIANN apresentou menores RMSE e viés em relação ao PERSIANN-CCS, e devido a sua alta latência de produção (2 dias) é indicado pelos autores para aplicações de monitoramento de inundação. Já o PERSIANN-

CDR possui a série histórica de maior extensão e é apropriado para investigar tendências estatísticas de eventos históricos de chuvas extremas e secas meteorológicas, bem como reconstruir observações históricas de vazões, em consequência de seu algoritmo levar em conta dados *in situ* da rede GPCP. Ainda assim, esse produto tende a subestimar eventos de precipitação extremos na escala diária.

O estudo de Zambrano-Bigiarini *et al.* (2017) verificou a adequação de sete SRE (TMPA 3B42v7, CHIRPSv2, CMORPH, PERSIANN-CDR, PERSIAN-CCS-Adj, MSWEPv1.1 e PGFv3) sobre a complexa topografia e os diversos gradientes climáticos do Chile. Utilizou-se 366 estações pluviométricas, as quais foram interpoladas sobre os *pixels* dos satélites (comparação ponto-a-*pixel*). A grande maioria dos produtos desempenharam melhor na região sul e na parte central do Chile, em particular nas menores altitudes (0-1000m) e nas estações úmidas (outono e inverno). O produto PGFv3 exibiu os melhores resultados em todas as localidades e em todas as escalas temporais, o que se atribui ao fato desse algoritmo utilizar dados de 217 estações da região na elaboração de seu produto.

Em estudo similar, Baez-Villanueva *et al.* (2018) aferiram seis produtos de satélite (TRMM 3B42v7, TRMM 3B42RT, CHIRPSv2, CMORPHv1, PERSIANN-CDR e MSWEPv2) sobre três bacias na América Latina (inclusive a bacia Paraíba do Sul) nas escalas diárias, mensais e sazonais. Os produtos CHIRPSv2 e MSWEPv2 foram interpolados por um processo de *upscaling* para comparação com os outros produtos utilizados numa mesma escala espacial. Os resultados mostram que, para a bacia Paraíba do Sul, o MSWEPv2 apresentou o melhor desempenho em escalas diárias e mensais, enquanto o CHIRPSv2 apresentou o melhor desempenho nessas escalas de tempo sobre a Bacia do Rio Magdalena, na Colômbia. Na Bacia do Rio Imperial, no Chile, o MSWEPv2 e o CHIRPSv2 apresentaram o melhor desempenho nas escalas diária e mensal, respectivamente. Quando as bacias foram avaliadas em escala sazonal, o CMORPHv1 apresentou o melhor desempenho nos meses de DJF e SON, o TRMM 3B42v7 nos meses de MAM e o PERSIANN-CDR nos meses de JJA sobre a bacia do Rio Imperial. O MSWEPv2 apresentou o melhor desempenho na Bacia Paraíba do Sul em todas as estações e o CHIRPSv2 apresentou-se melhor na Bacia do Magdalena. Em relação ao processo de interpolação, os autores indicam que deve-se avaliar os SRE antes e após o processo de *upscaling*, visto que esse processo pode ser indiferente, melhorar ou até piorar o desempenho dos produtos, principalmente em regiões montanhosas.

Huang, Chang e Liu (2018) avaliaram o produto IMERG sobre uma rede de pluviômetros interpoladas em Taiwan na mesma escala espacial do produto de satélite ($0,1^\circ \times 0,1^\circ$). Os resultados mostram que o produto subestima as precipitações em todas as escalas temporais analisadas (anual, sazonal, diária e sub-diária) e espacialmente apresenta viés elevado sobre as regiões montanhosas. Apesar da diferença na magnitude dos valores, o IMERG foi capaz de reconhecer qualitativamente padrões de chuvas sobre a região.

De forma sumária, os estudos citados e outros presentes na literatura atual (CARACCIOLO *et al.*, 2018; FARIDZAD *et al.*, 2018; ZENG *et al.*, 2018) indicam que, na maioria dos casos, os SRE apresentam elevado viés e são incapazes de representarem o regime de chuvas de uma região e portanto, os resultados desses trabalhos não podem ser extrapolados para outras bacias. Isso retrata que os mesmos produtos de satélite apresentam comportamento diferente em áreas similares. Em vista disso, *a priori*, sempre se tornam necessárias validações desses produtos para identificação e caracterização de suas incertezas.

3.3.3 Correção de viés dos produtos de satélite

A precisão de qualquer estudo hidrológico (previsão de cheias, monitoramento de secas, gestão de recursos hídricos) depende muito da disponibilidade de estimativas de precipitação de boa qualidade. Contudo, conforme exemplificado pelos estudos citados, as estimativas de precipitação por satélite possuem viés, o qual advém de diferentes fontes, incluindo erro de amostragem, limitações técnicas do próprio sensor e da compreensão limitada dos algoritmos sobre o fenômeno da precipitação.

O viés nas estimativas de precipitação por satélite não se limita somente a médias mensais. Medidas de importância hidrológica como diferenças na variabilidade das intensidades de precipitação, em valores extremos diários, na quantificação de períodos de estiagem, entre a frequência de dias secos das distribuições modelada e observada, assim como em outros momentos estatísticos descritivos (assimetria e curtose) dessas distribuições (LAFON *et al.*, 2013), também podem ser afetadas.

Técnicas para corrigir o viés nos resultados das estimativas de precipitação por satélites são, portanto, usadas para melhorar o realismo de suas séries temporais com base nas propriedades estatísticas obtidas a partir de dados observados no mesmo período de referência. Ademais, devido a problemas na operação das redes pluviométricas, a existência de falhas nas séries

históricas de precipitação não é incomum. Logo, as estimativas de satélite corrigidas são uma fonte alternativa de dados que pode ser utilizada em casos necessários. Ademais, previsões de volume acumulado de chuva de dados de satélite corrigidos, durante um intervalo de tempo, podem até ser mais fidedignas do que volumes estimados a partir de dados observados.

Muitos métodos de correção de viés têm sido propostos na literatura com o âmbito de corrigir o viés médio das estimativas de sensores orbitais. Dentre eles, os modelos lineares simples computam fatores de correção (ou de escala) que podem ser aditivos ou multiplicativos em relação aos dados de referência (pluviômetros). Em seguida, esses fatores são aplicados aos dados originais dos SRE, sob a perspectiva de reduzir o viés identificado.

Beaufort, Gibier e Palany (2019) calcularam fatores aditivos e multiplicativos considerando séries históricas de 70 estações pluviométricas na Guiana Francesa e os aplicaram em três produtos de satélite TMPA, IMERG e o HE. Os autores obtiveram um viés absoluto menor que 8 mm/dia e um RMSE inferior a 12 mm/dia. Já na escala anual, o viés foi completamente removido. Do mesmo modo, Worqlul *et al.* (2018) realizaram uma regressão linear para corrigir as estimativas do produto MPEG em uma bacia na Etiópia. A técnica reduziu o viés e manteve o coeficiente de correlação linear constante. Consequentemente, a vazão simulada pelos dados corrigidos foi equiparável a vazão simulada pelos dados dos pluviômetros.

Outros estudos propuseram uma relação não linear (funções potência e exponencial) entre a variável explicativa (SRE) e a variável resposta (pluviômetros) com o mesmo objetivo. Piani *et al.* (2010) fizeram uma comparação entre modelos lineares e não lineares para correção da precipitação diária. Os autores utilizaram como base de dados estações espalhadas por todo o globo com séries de comprimento de 30 anos. Os resultados mostram que a correção de viés melhorou tanto a média quanto a variância dos campos de chuva em todas as regiões do globo.

Abordagens estatísticas também foram testadas. O mapeamento de quantis (MQs) é uma técnica que concebe uma função de transformação entre a variável modeladas (SRE) e a observada (pluviômetros). Essa função equaliza as funções de distribuição acumulada entre as variáveis por meio do ajuste dos momentos dessas distribuições (

Figura 3.6). Com isso é possível corrigir os dados de satélite aproximando-os dos dados observacionais (MARAUN, 2016). As vantagens dessas técnicas probabilísticas perante as

abordagens determinísticas é que elas tentam ajustar, além da média e desvio padrão, momentos de ordem superior da distribuição observada.

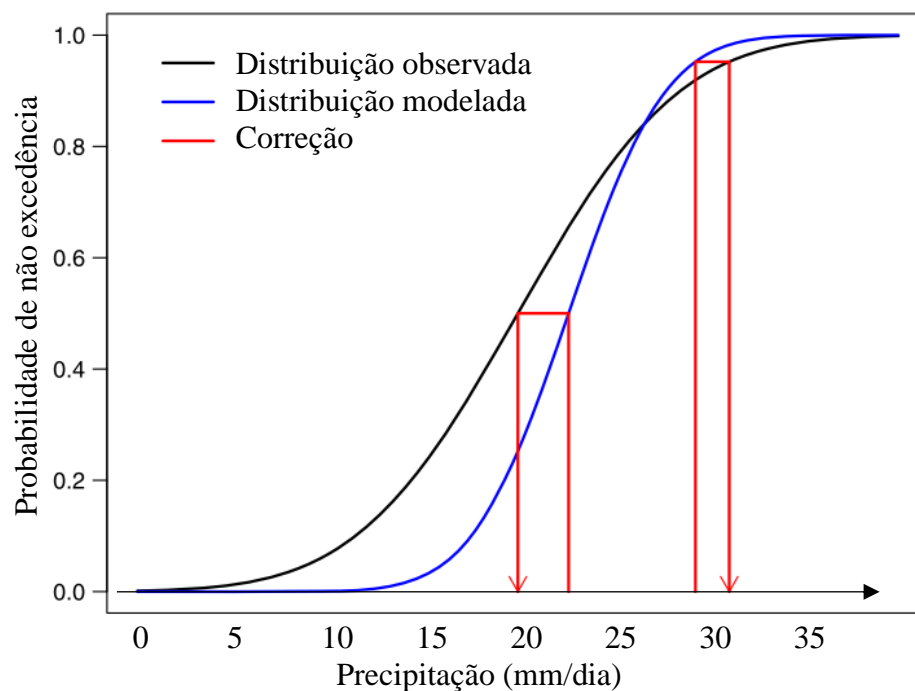


Figura 3.6 – Representação gráfica da técnica mapeamento de quantis.

Fonte: Adaptado de Maraun (2016).

O MQ pode ser concebido de duas formas: paramétrica e não paramétrica. A concepção é dita paramétrica ou transformação derivada de distribuição, quando se conhece a distribuição teórica de ambas as variáveis. Muitos estudos consideram a distribuição Gama como a mais eficiente em modelar o histograma da precipitação diária (BEAUFORT; GIBIER; PALANY, 2019; PIANI; HAERTER; COPPOLA, 2010). Evidentemente, devido ao conhecimento dos parâmetros dessas distribuições, as mesmas permitem extrapolação, facilidade de simulação, e uma melhor previsão dos comportamentos distintos nas caudas (leve e pesada).

A abordagem não paramétrica ou transformação empírica é mais flexível, pois não requer hipóteses *a priori* acerca da distribuição, e admite distribuições de frequência empíricas complexas como, por exemplo, distribuições bimodais. Entretanto, possuem dificuldades em extrapolar dados superiores aos quantis não observados e necessitam de modelos adicionais (tipo spline) aumentando as incertezas preditivas. No estudo de Abera, Brocca e Rigon (2016), cinco produtos de satélite de alta resolução (3B42V7, CMORPH, TAMSAT, SM2R-CCI e CFSR) tiveram as distribuições de suas intensidades de chuva corrigidas pela técnica de mapeamento de quantis por distribuição empírica. O método melhorou a estimativa de

precipitação de todos os SRE, e o melhor desempenho foi obtido para o CMORPH (redução de viés de 72% para 1%).

Grande parte dos estudos comparam diversas técnicas de correção de viés sobre uma dada região com o intuito de verificar o desempenho dessas. Lafon *et al.* (2013) compararam quatro técnicas (linear, não linear, MQs baseado nas distribuições Gama e empírica) para correção de viés de precipitação diária através de medidas de erro dos quatro primeiros momentos estatísticos de séries temporais de sete bacias localizadas ao longo da Inglaterra. No geral, a distribuição Gama apresentou a melhor combinação de precisão e robustez. Os autores evidenciaram que várias das técnicas foram sensíveis a escolha do período de calibração.

Em estudo semelhante, Gudmundsson *et al.* (2012) comparou várias funções de transformação para correção de viés (distribuições teóricas Bernoulli-Gama, Bernoulli-Weibull, Bernoulli-Log Normal Bernoulli-Exponencial, distribuição empírica, modelo Spline, além de 5 modelos paramétricos, incluindo lineares e não lineares) utilizando séries de precipitações diárias de 82 estações da Noruega. A transformação não paramétrica foi a que mais reduziu o viés sistemático das séries de um modelo RCM (*Regional Climate Model*).

Objetivando aprimorar o MQs não paramétrico, Yang *et al.* (2016) propuseram uma nova técnica que o mescla com um esquema de interpolação por ponderação gaussiana. Os resultados mostram que o viés dos dados do PERSIANN-CCS foi efetivamente reduzido. Os padrões espaciais de precipitação corrigida apresentaram alta consistência com as observações de superfície, com RMSE e viés médio reduzidos. O viés sistemático da série temporal do PERSIANN-CCS, tanto nas escalas mensal como diária, foi removido.

4. METODOLOGIA

O fluxograma da Figura 4.1 sintetiza a metodologia de trabalho, a qual consiste em duas etapas principais: (i) identificação das diferenças entre os pluviômetros e os produtos de satélite e (ii) aplicação de técnicas para correção de viés.

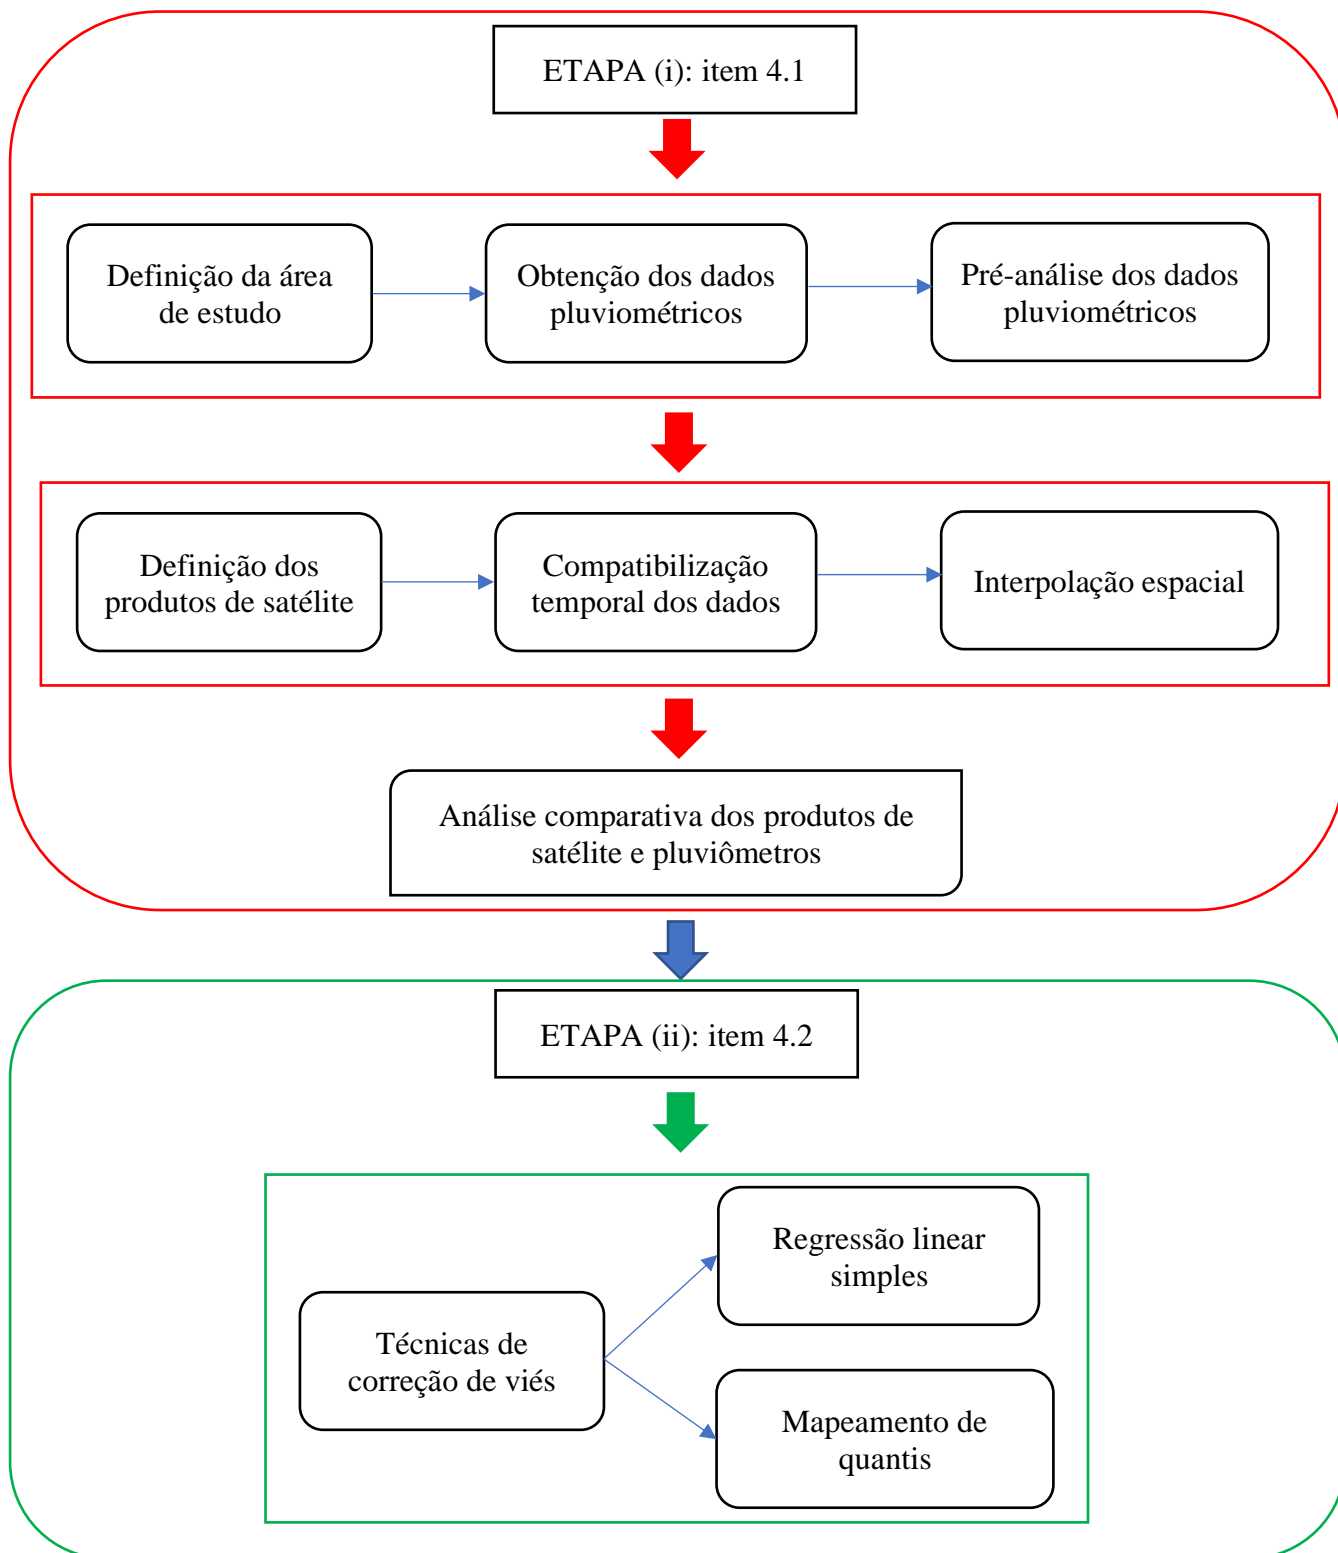


Figura 4.1 – Fluxograma da metodologia adotada.

Procede-se a seguir com a descrição pormenorizada das etapas da metodologia citadas.

4.1 Etapa 1 – Identificação das diferenças entre os pluviômetros e produtos de satélite

4.1.1 Definição da área de estudo

A bacia do rio Paranaíba está inserida na região de ocorrência dos biomas Cerrado e Mata Atlântica, encontrando-se bastante desmatada em função das atividades antrópicas. O Cerrado possui 22,4% de sua cobertura original, enquanto a Mata Atlântica apenas 14,4%. Considerando ambos os biomas, a cobertura vegetal nativa remanescente alcança 21,8% de sua área total original (ANA, 2015).

A escolha da bacia do rio Paranaíba fundamentou-se em alguns aspectos. A bacia é caracterizada pelo uso antagônico do recurso hídrico disponível. De um lado, tem-se a priorização hídrica voltada ao consumo, o qual está associado ao abastecimento populacional, desenvolvimento econômico e às demandas da agroindústria, a principal atividade econômica da região (ANA, 2015). Por outro lado, os requisitos de reserva hídrica voltados para o planejamento/operação do setor elétrico, visto que esta bacia possui o maior índice de aproveitamento hidrelétrico inventariado do Brasil (ANEEL, 2008). Portanto, ao ser mais assertivo na caracterização hidrológica das precipitações, otimiza-se a distribuição do recurso hídrico disponível de forma mais justa.

Outro aspecto é que apesar da bacia possuir uma densidade de estações pluviométricas que atende as recomendações mínimas da OMM (OMM, 2014) por unidade fisiográfica (Tabela 4.1), que em média é de 575 km²/estação, espacialmente, o número de pluviômetros são insuficientes para representar a distribuição espacial da chuva. Logo, a informação disponível é deficiente para aplicações de monitoramento em tempo real. Independentemente, erros oriundos da operação/manutenção desses equipamentos constituem-se em fontes de incerteza associadas às medições dessa variável hidrológica. Contrariamente, o monitoramento de precipitações por satélite fornece informações mais confiáveis sobre a distribuição espacial do fenômeno.

Tabela 4.1 – Recomendações de densidade mínima de estações por unidade fisiográfica.

Unidades Fisiográficas	Pluviômetro	Pluviógrafo
Litoral / Região Costeira	900	9.000
Montanhas	250	2.500
Planícies Interioranas	575	5.750
Ondulada / Montanhosa	575	5.750
Pequenas Ilhas (< 500 km ²)	25	250
Áreas Urbanas	-	10 a 20
Polar / Árida	10.000	100.000

Fonte: Adaptado de OMM (2014).

Um terceiro aspecto é que a bacia apresenta uma uniformidade espacial de chuvas ao longo de seu perímetro (ANA, 2015). Portanto, ao considerar as macrorregiões da bacia (regiões norte, sul, leste e oeste), nota-se hietogramas de chuva média mensal similares em algumas estações (Figura 4.2). Isso indica uma baixa variabilidade espacial de precipitação e essa uniformidade é um indicativo de que os fenômenos meteorológicos que produzem excessos e/ou escassez de chuvas nessa região possam ser mais facilmente categorizados. Logo, espera-se que os satélites caracterizem as chuvas de forma mais similares em todas as regiões da bacia.

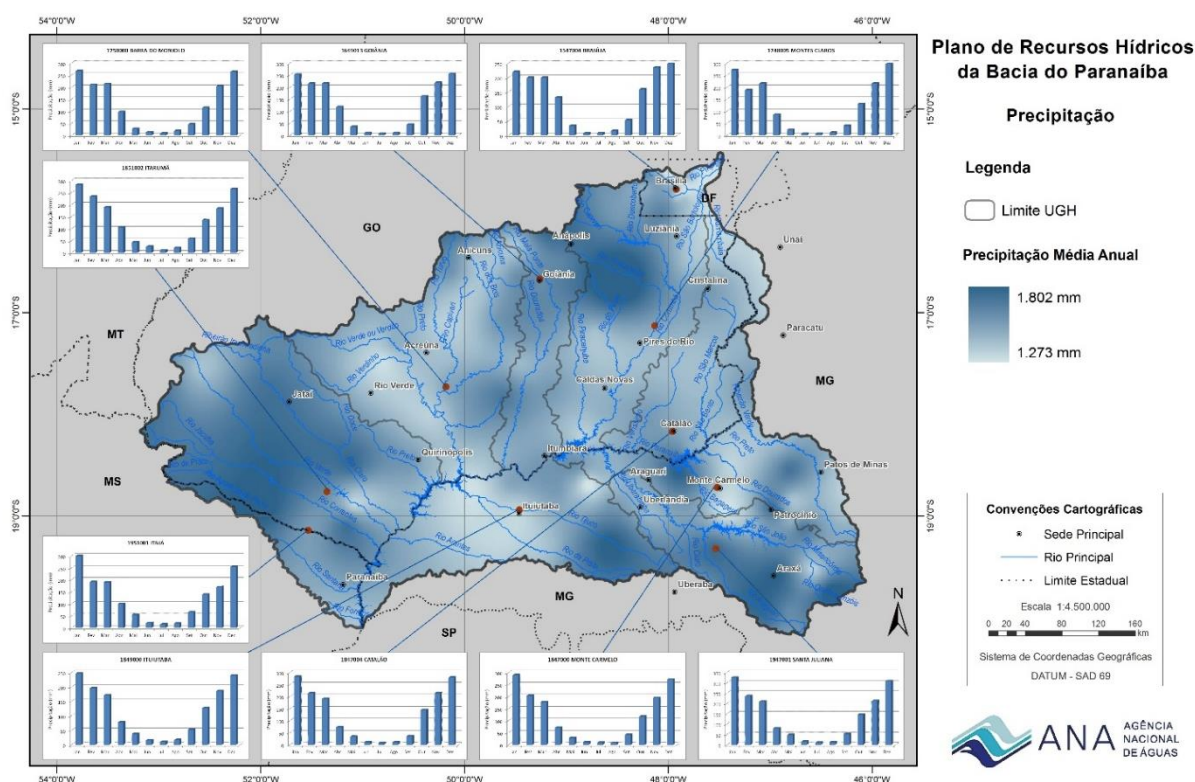


Figura 4.2 – Precipitação média mensal sobre a bacia do Rio Paranaíba.

Fonte: ANA (2015).

Com relação ao uso e ocupação do solo, o estudo de Reis *et al.* (2016) realizou um mapeamento no sudoeste goiano de áreas de risco à ocorrência da erosão hídrica com base no modelo clima-solo-relevo, indicando que no oeste da bacia do rio Paranaíba há áreas com risco de extremamente forte a moderado. Como essa região há um numero menor de pluviômetros em operação em relação aos outra regiões da bacia (ANA, 2015), a utilização das informações fornecidas pelo monitoramento dos satélites pode subsidiar a tomada de decisão relacionada a planos de risco de acidentes.

4.1.1.1 Aspectos fisiográficos

A bacia hidrográfica do rio Paranaíba é a segunda maior unidade da Região Hidrográfica do Paraná, ocupando 25,4% de sua área, e está localizada entre os paralelos 15° e 20° sul e os meridianos 45° e 53° oeste, com uma área de drenagem de 222,6 mil km². Posicionada na região central do Brasil, inclui os estados de Goiás, Minas Gerais e Mato Grosso do Sul, além do Distrito Federal (Tabela 4.2). A bacia está inserida na região de ocorrência dos biomas Cerrado e Mata Atlântica, encontrando-se bastante desmatada em função das atividades antrópicas.

Tabela 4.2 – Participação das unidades da federação na bacia do rio Paranaíba.

Unidade da Federação	Área da bacia	
	km ²	(%)
Distrito Federal	3.665	1,6
Goiás	140.832	63,3
Minas Gerais	70.503	31,7
Mato Grosso do Sul	7.592	3,4
Total	222.593	100

Fonte: ANA (2015).

A bacia do rio Paranaíba apresenta variação de 240 m a 1400 m de altitude, com as menores altitudes acompanhando o curso principal do rio Paranaíba e, principalmente, a região da sua foz, localizada na Província Paraná (porção sudoeste da bacia) (Figura 4.3) (ANA, 2015). Já as maiores cotas altimétricas ocorrem nas porções nordeste e sudeste, as quais integram a Província Tocantins. Do ponto de vista geomorfológico, são definidos dois conjuntos de relevo na bacia do rio Paranaíba: o Planalto Central Goiano e o Planalto Setentrional da Bacia do Paraná.

O mapeamento do atual uso e ocupação do solo na bacia do rio Paranaíba demonstra a predominância das atividades agropecuárias em cerca de 70% da área da bacia (Figura 4.4). A

pecuária é predominante no setor oeste, enquanto a agricultura domina a porção centro-sudeste e diversas áreas de cabeceira de drenagem da bacia.

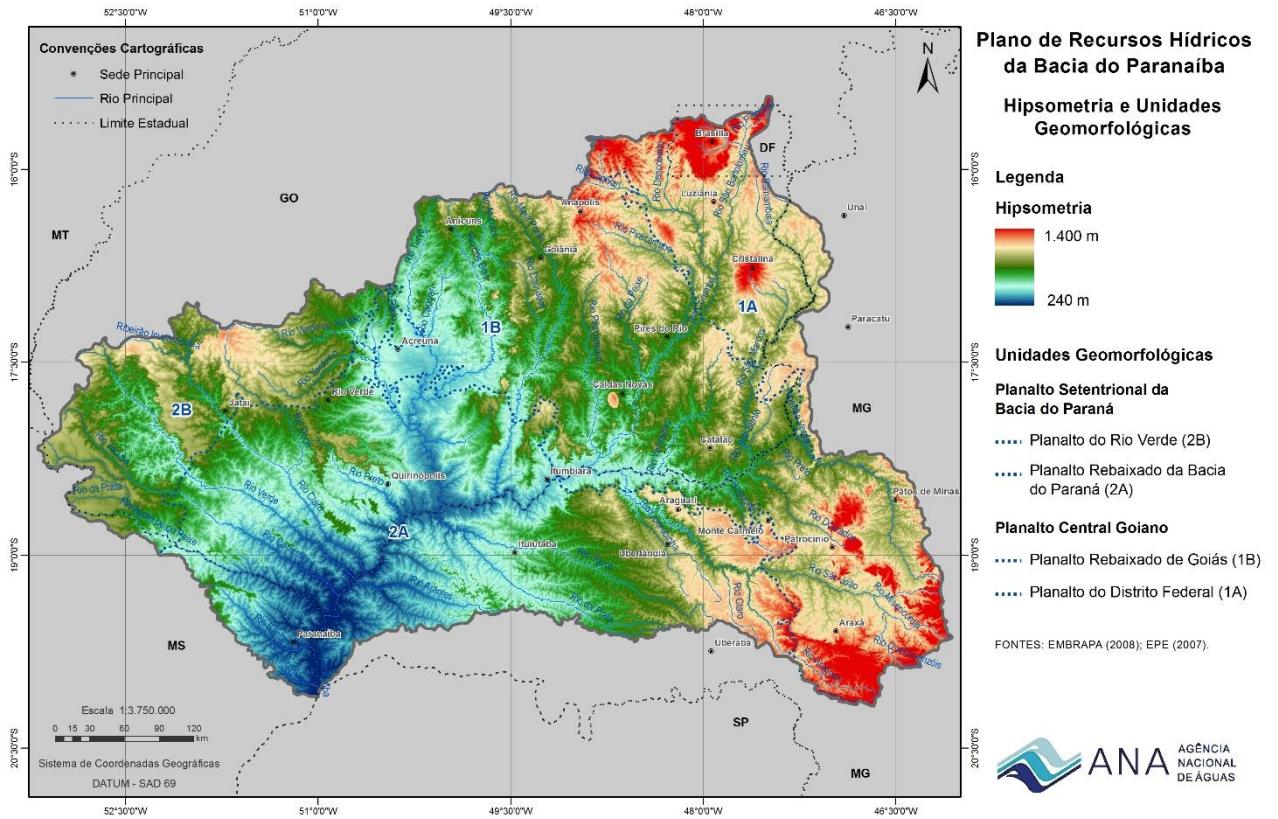



Figura 4.3 – Hipsometria e unidades geomorfológicas.

Fonte: ANA (2015).



Fonte: ANA

Figura 4.4 – Uso e ocupação do solo nas UGH.

Fonte: ANA (2015).

4.1.1.2 Aspectos climatológicos

O sistema atmosférico de escala sinótica que afeta a bacia do rio Paranaíba é a Zona de Convergência do Atlântico Sul (ZCAS). A ZCAS é formada pela associação entre a frente polar Atlântica e as linhas de instabilidades, principalmente provenientes da Região Amazônica. A orientação NO-SE da ZCAS é determinada pela contribuição da Frente Polar Atlântica que, sobre o continente, apresenta essa mesma direção preferencial. A ZCAS e as Frentes Frias são as principais responsáveis pela precipitação. Já o Anticiclone Subtropical do Atlântico Sul e o Vórtice Ciclônico de Ar Superior ocasionam a maioria dos períodos de estiagem (SILVA; FERREIRA, 2015).

Segundo a classificação climática de Köppen, a bacia possui clima tropical quente em todas as estações do ano (temperatura média mensal maior ou igual a 18°C) e inverno seco. As precipitações médias anuais variam de 1.435 mm na Unidade de Gestão Hídrica (UGH) – divisões hidrográficas adotadas pelas unidades da federação e são representadas pelas divisões hidrográficas estaduais, adotadas pelos Estados para a realização da gestão de recursos hídricos – do Distrito Federal a 1.592 mm na UGH Santana-Aporé, não havendo variações extremas entre as Unidades de Gestão Hídrica (UGHs) (Figura 4.5).

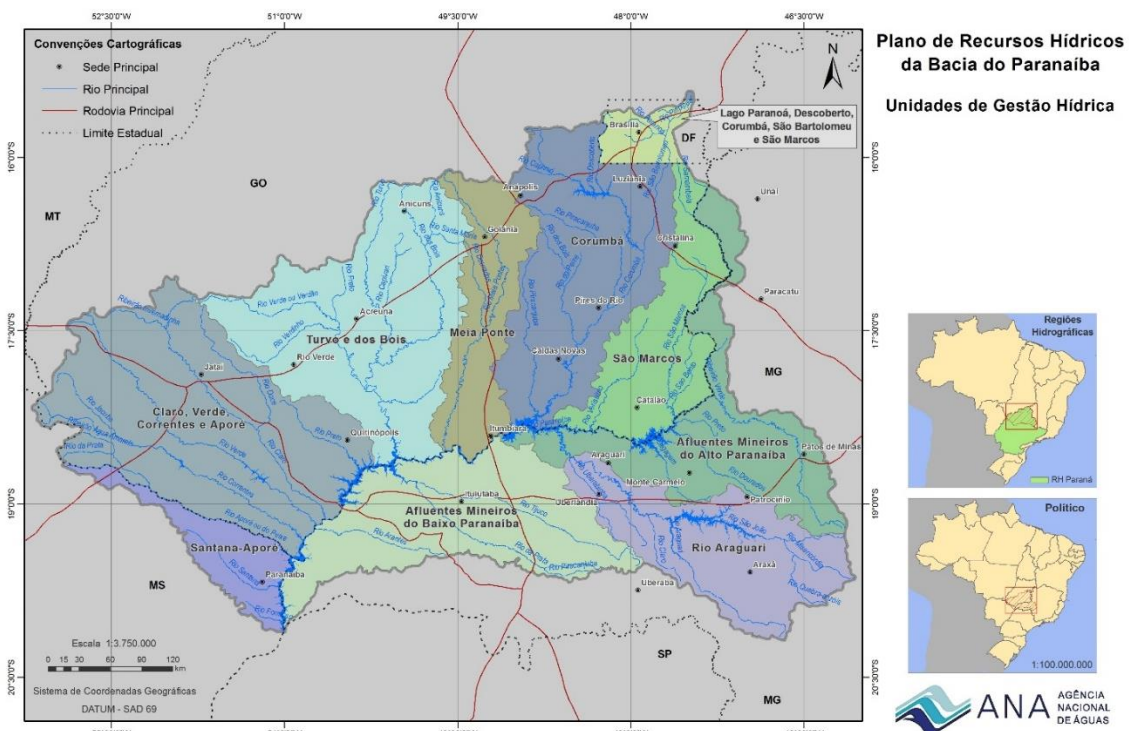


Figura 4.5 – Unidades de Gestão Hídrica (UGH) da bacia do rio Paranaíba.

Fonte: ANA (2015).

O valor médio anual da precipitação na bacia do rio Paranaíba situa-se em torno de 1.500 mm. Valores mais elevados são encontrados na parte setentrional da bacia do rio Corumbá e na região sudeste (cabeceras da bacia do rio Araguari e do Alto Paranaíba), onde as altitudes são mais elevadas, enquanto as regiões de menor pluviosidade estão situadas próximas da região sudoeste, prolongando-se para a região central (Médio Paranaíba).

Em termos genéricos, o clima da bacia apresenta duas estações bem definidas: uma concentra grande parte das precipitações anuais (estação chuvosa) e outra um decréscimo ou ausência de precipitações (estação seca). Observa-se uma marcada sazonalidade em que os meses secos (maio a setembro) apresentam precipitação média mensal inferior a 50 mm, com valores próximos de zero, e os meses úmidos (outubro a abril) apresentam precipitação média mensal que supera 100 mm, podendo chegar a 400 mm (Figura 4.2). A distribuição pluviométrica anual caracteriza a existência de uma estação seca em toda a região, com duração entre três e quatro meses do ano (de maio/junho a agosto) (ANA, 2015).

4.1.2 Obtenção e pré-análise dos dados pluviométricos

Os dados de precipitação diária oriundas de pluviômetros foram obtidas *online* pelo portal *HidroWeb*, que é uma ferramenta integrante do Sistema Nacional de Informação em Recursos Hídricos (SNIRH), de responsabilidade da ANA. Inicialmente empregou-se o inventário (*shapefile*; disponível no portal metadados.ana.gov.br) que contém todas as estações pluviométricas cadastradas na Rede Hidrometeorológica Nacional (RHN). Com isso, foram identificadas e selecionadas todas as estações pertencentes ao domínio da sub-bacia do Rio Paranaíba, obtendo um total de 542 estações pluviométricas. Desse total, somente as séries históricas de 242 postos pluviométricos estavam disponíveis no portal, as quais foram obtidas pelo sistema *HidroWeb* em março de 2018.

Primeiramente, as estações que continham somente registros temporais anteriores aos produtos de satélite foram excluídas. Na sequência, procedeu-se a uma análise preliminar dos dados, sob o propósito de se construir uma amostra "consistente" do regime pluviométrico regional. Em síntese, avaliou-se o número de falhas e a presença de *outliers* nas séries das estações nas escalas mensal e anual. Na Tabela 4.3 são indicados os critérios empregados. Eles foram construídos considerando-se as recomendações publicadas no guia "Orientações para consistência de dados pluviométricos" da ANA (ANA, 2012).

Tabela 4.3 – Critérios empregados durante a análise preliminar dos dados de pluviômetros.

Escala temporal	Grandeza	Critério para eliminação
Anual	<i>Nº de falhas</i>	Inferior a 12 meses, observando-se o critério mensal
	<i>Outliers</i>	Acumulados anuais inferiores a 600 mm Acumulados anuais superiores a 3.750 mm
Mensal	<i>Nº de falhas</i>	Meses Abril-Junho: acima de 5 falhas diárias/mês Meses Julho-Setembro: acima de 7 falhas diárias/mês Meses Outubro-Março: acima de 3 falhas diárias/mês
	<i>Outliers</i>	Acumulados mensais inferiores ao quantil 2,5% Acumulados mensais superiores ao quantil 97,5% Acumulados mensais superiores a 1.500 mm

Em relação à análise preliminar, é necessário destacar que o seu objetivo primordial foi remover da série histórica registros/períodos nos quais inferiu-se que erros de observação eram mais prováveis. Sabe-se que, independentemente dos critérios, sempre existirá a possibilidade da exclusão de registros corretos e/ou a permanência de totais acumulados diários errôneos. Uma avaliação mais detalhada (análise de consistência) nessa escala (242 estações pluviométricas), é incompatível com o cronograma de trabalho. Sendo assim, assume-se: (i) que os dados disponíveis no SNIRH, em sua grande maioria, apresentam os requisitos de qualidade necessários à elaboração de um estudo dessa natureza; (ii) que os registros presentes na série após a análise preliminar são capazes de representar “consistentemente” o regime pluviométrico da região; e (iii) que eventuais exclusões equivocadas de registros não causarão uma redução expressiva do comprimento das séries históricas. Ao final da análise preliminar, restaram 166 estações nas escalas diária e mensal (Figura 4.6). Já na escala anual restaram 143 postos pluviométricos.

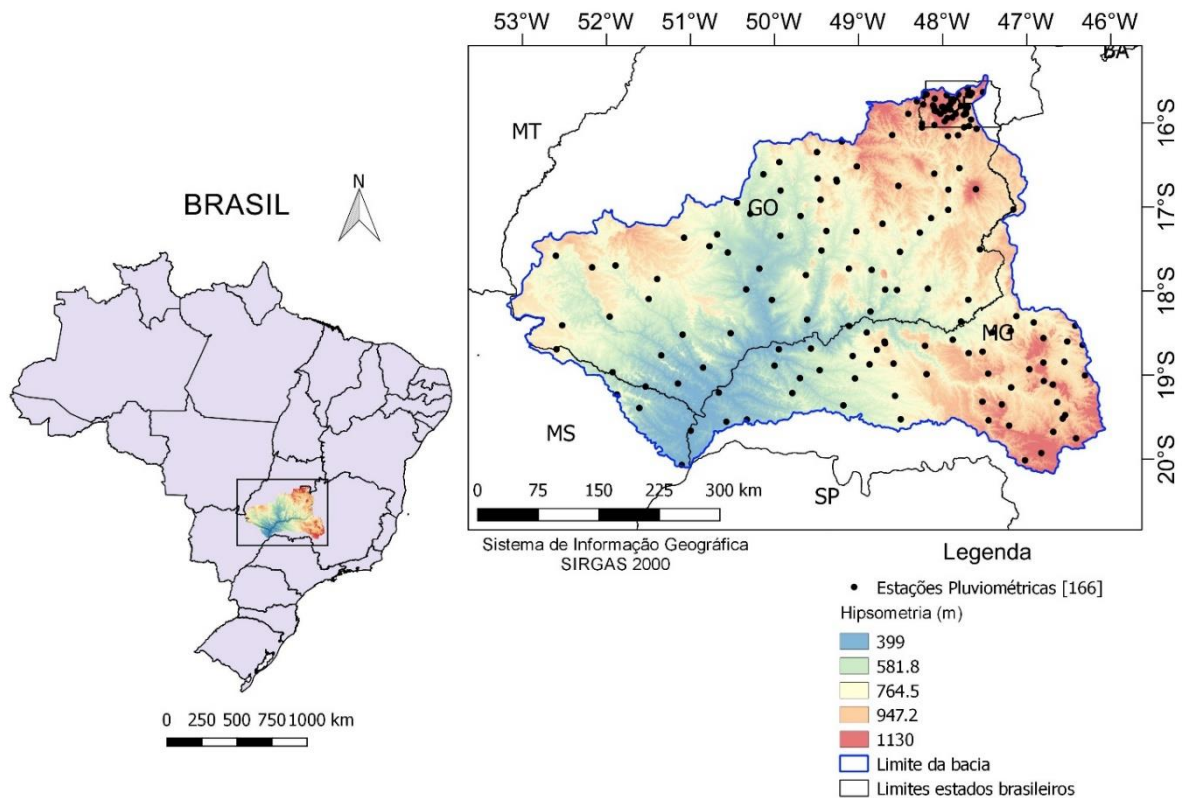


Figura 4.6 – Localização das estações pluviométricas empregadas.

4.1.3 Definição dos produtos de satélites

O conjunto de dados de estimativas de precipitação por satélite abrange o período de 01 de março de 2000 à 31 de dezembro de 2017, totalizando aproximadamente 17 anos de dados. Foram selecionados três produtos de estimativa de precipitação por satélite, os quais serão brevemente descritos nas seções subsequentes, sendo eles: o CMORPH_v1.0-CRT, PERSIANN e TMPA 3B42.

Esses produtos foram extensivamente referenciados na literatura recente por sua aplicação em regiões tropicais (BEAUFORT; GIBIER; PALANY, 2019; LAVERDE-BARAJAS *et al.*, 2018; PALOMINO-ÁNGEL; ANAYA-ACEVEDO; BOTERO, 2019). Além disso, os produtos de satélite selecionados possuem cobertura espacial da região de estudo e com séries históricas representativas (~ 20 anos).

CMORPH_v1.0-CRT

O produto de estimativa de precipitação *Climate Prediction Center (CPC) MORPHing technique* (CMORPH) foi concebido pelo *National Centers for Environmental Prediction* (NCEP) do NOAA. Originalmente tal técnica utilizava, exclusivamente, estimativas de

precipitação derivadas dos sensores passivos de MO a bordo de satélites LEO, sendo eles: o SSM/I a bordo dos satélites DMSP 13 a 15; do AMSU-B presentes nos satélites NOAA 15 a 17 e TMI do satélite TRMM. Essas estimativas são geradas pelos algoritmos de Ferraro (1997) para o SSM/I, Ferraro *et al.* (2000) para AMSU-B e Kummerow *et al.* (2001) para o TMI e propagadas no tempo e no espaço utilizando informações obtidas inteiramente a partir de sensores infravermelhos a bordo de satélites geoestacionários, sendo eles: os GOES 8 e 10; os MeteoSat 5 e 7 e o GMS-5 (JOYCE *et al.*, 2004).

Explicitando, o algoritmo concebe vetores de movimento de aglomerados de nuvens utilizando imagens consecutivas dos canais IV a bordo de satélite GEO por meio de correlação cruzada. Então, as estimativas instantâneas de precipitação geradas por qualquer sensor passivo de MO disponível são propagadas no tempo e no espaço por esses vetores, fornecendo produtos de resolução temporal de 30 min e espacial de 8 km x 8 km sobre o globo. Portanto, o produto CMORPH não é um algoritmo de estimativa de precipitação em si, mas uma técnica pela qual as estimativas dos algoritmos de precipitação dos sensores de micro-ondas existentes podem ser combinadas. Consequentemente, o método é bastante flexível, pois admite-se incorporar no produto final quaisquer satélites que possuam, como fonte de estimativas de precipitação, sensores do tipo MO. Esse produto recebe atualmente a nomenclatura de CMORPH_v0.x. e está disponível nas seguintes resoluções temporais e espaciais:

- i. 30 min à 8 km² no Equador;
- ii. 3 h à 0,25° x 0,25° e
- iii. diária à 0,25° x 0,25°.

Recentemente Xie *et al.* (2017) reprocessaram e propuseram um produto com o viés corrigido advindo do CMORPH_v0.x. Nesse procedimento, os autores utilizaram o mapeamento de quantis utilizando informações diárias de superfície da rede CPC desde janeiro de 1998 até os dias atuais para formar um Registro de Dados Climáticos (CDR do inglês *Climate Data Record*) de alta resolução. O resultado é o produto denominado CMORPH_v1.0-CRT, o qual é utilizado nesse estudo. O mesmo possui resolução temporal de 3h e espacial de 0,25° x 0,25°, com cobertura espacial de 60°N-60°S e de latência de produção de 5 meses. Os dados foram obtidos no site do NOAA pelo link: ftp://ftp.cpc.ncep.noaa.gov/precip/CMORPH_V1.0/CRT/0.25deg-3HLY/.

PERSIANN

A estimativa de precipitação PERSIANN (do inglês *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks*) foi desenvolvida em 1997 pelo Centro de Hidrometeorologia e Sensoriamento Remoto (CHRS, do inglês *Center for Hydrometeorology and Remote Sensing*) da Universidade da Califórnia nos Estados Unidos.

Referenciando-se por Hsu *et al.* (1997), o produto utiliza uma rede neural para criar uma função de classificação das imagens dos sensores infravermelhos de satélites GEO. Essas imagens são transformadas em uma camada oculta com o objetivo de detectar e classificar padrões nos dados de entrada. Posteriormente, tal camada oculta é transformada em taxas de precipitação (saída). O processo de entrada-transformação-saída envolve estimação de parâmetros, os quais são adaptados continuamente pelas imagens dos sensores passivos de MO dos satélites em órbita terrestre baixa. Portanto, o algoritmo não utiliza dados em si de sensores passivos de MO no seu produto, mas os usa para calibração de suas estimativas de IV.

Originalmente o produto usou somente imagens dos sensores da banda do IV como entrada principal para o algoritmo, no entanto, posteriormente incluiu imagens diurnas dos sensores da banda Vis (SOROOSHIAN *et al.*, 2000). O algoritmo produz estimativas de precipitação em escala global entre as latitudes 60°S e 60°N e atualmente, utiliza informações dos satélites GOES-15 (Goes-West), GOES-16 (Goes-East), Meteosat-11 (MSG), Meteosat-8 (MIO) e Himawari-8 (HIM). Os dados do produto PERSIANN foram obtidos por meio do portal público do CHRS, através do link <http://chrdata.eng.uci.edu>, nas escalas temporal e espacial de 3h e 0,25° x 0,25°. O produto possui uma latência de produção de 2 dias.

TMPA 3B42

Desde o seu lançamento em 1997, a missão *Tropical Rainfall Measuring Mission* (TRMM) realizada em consórcio pela *National Aeronautics And Space Administration* (NASA) e a *Japan Aerospace Exploration Agency* (JAXA), forneceu diversas estimativas de precipitação nas regiões tropicais e subtropicais do planeta. Tal missão foi a primeira dedicada a monitorar as chuvas tropicais com o intuito de identificar a sua influência em mudanças climáticas (HUFFMAN *et al.*, 2007). Assim como a missão, o satélite recebeu o nome de TRMM e esteve em órbita terrestre no período entre novembro de 1997 e junho de 2015, quando o satélite reentrou na atmosfera terrestre. Entretanto, o produto TMPA 3B42 continua produzindo dados

até hoje utilizando informações obtidas dos satélites LEO DMSP-F16 a F18, NOAA-18 e 19, MetOp-A e B e dos satélites GEO GOES, GMS, Himawari e Meteosat.

Segundo Huffman *et al.* (2007), o produto TMPA é concebido em cinco estágios principais: (i) as estimativas dos sensores passivos de MO são computadas pelo algoritmo de Kummerow *et al.* (2011); (ii) as estimativas MO são calibradas e combinadas; (iii) estimativas de IV são criadas baseando-se nas estimas de MO combinadas; (iv) as estimativas das etapas (ii) e (iii) são combinadas; e (v) é aplicada uma técnica de correção de viés utilizando dados de superfície da rede GPCC.

O produto resultante é mais preciso e adequado para pesquisa segundo Huffman *et al.* (2007), e é disponibilizado aos usuários cerca de dois meses após as observações iniciais sobre a região. As estimativas de precipitação utilizadas estão em grades de $0,25^\circ \times 0,25^\circ$ e na escala temporal de 3h em um domínio quase global que varia na faixa latitudinal de 50°S a 50°N . Eles foram obtidos no domínio <https://pmm.nasa.gov/data-access/downloads/trmm>. Sumariamente, as principais características dos produtos utilizados estão resumidas na Tabela 4.4.

Tabela 4.4 – Principais características dos produtos de satélite utilizados.

Nome do produto	Escala temporal	Escala espacial	Cobertura global
CMORPH_v1.0-CRT	3 horas	$0,25^\circ \times 0,25^\circ$	$60^\circ\text{N} - 60^\circ\text{S}$
PERSIANN	3 horas	$0,25^\circ \times 0,25^\circ$	$60^\circ\text{N} - 60^\circ\text{S}$
TMPA 3B42 Research Version	3 horas	$0,25^\circ \times 0,25^\circ$	$50^\circ\text{N} - 50^\circ\text{S}$

Algoritmos na linguagem R foram desenvolvidos para acesso e manipulação dessas informações. Cabe destacar que em função do horário de observação dos pluviômetros monitorados pela ANA (7h a 7h) foi necessário o download dos dados em uma resolução temporal inferior à diária (3h). Posteriormente, foi realizada uma agregação temporal para compatibilização entre as fontes de dados utilizadas (arquivos de satélites e registros dos pluviômetros).

4.1.3.1 Compatibilização temporal dos registros

Os arquivos de 3h dos produtos CMORPH, PERSIANN e TMPA 3B42 são nomeados em função do fuso GMT. Os oito arquivos diários possuem a indicação do horário de monitoramento em seus nomes (00, 03, 06, 09, 12, 15, 18 e 21; *labels*). No caso dos produtos CMORPH e PERSIANN, cada arquivo representa a precipitação acumulada durante três horas. É válido lembrar que o horário oficial de Brasília, horário local da bacia de estudo, está três

horas atrasado em relação ao GMT. Logo, por exemplo, um arquivo que inclui 09 em seu nome registra o que ocorreu às 06 h na bacia do Paranaíba.

Já o produto TMPA 3B42 é elaborado de forma diferente. Apesar dos *labels* dos arquivos serem os mesmos dos outros produtos, cada um representa uma intensidade de precipitação em mm/hr centrada na numeração do *label*. Exemplificando, o arquivo de *label* 06 representa uma intensidade média de precipitação que ocorreu das 04:30 as 07:30, ou seja, 1h30min antes e depois do nome do respectivo *label*.

A Figura 4.7 abaixo representa a agregação temporal dos dados realizada para cada produto para sua compatibilização com a metodologia de registro de dados de pluviômetros utilizada pela ANA.

PRODUTOS UTILIZADOS	DIA 01 - SATÉLITES				DIA 02 - SATÉLITES				DIA 03 - SATÉLITES				Coordenada de tempo				
	0	3	6	9	12	15	18	21	0	3	6	9		12	15	18	21
CMORPH	0	3	6	9	12	15	18	21	0	3	6	9	12	15	18	21	UTC
PERSIANN	0	3	6	9	12	15	18	21	0	3	6	9	12	15	18	21	UTC
TMPA 3B42	0	3	6	9	12	15	18	21	0	3	6	9	12	15	18	21	UTC
Pluviômetros ANA	10				10				10				UTC				
	DIA 00 - ANA				DIA 01 - ANA				DIA 02 - ANA				DIA 03 - ANA				

Figura 4.7 – Compatibilização temporal dos arquivos de satélite e pluviômetros da ANA.

Os arquivos dos produtos CMORPH e PERSIANN foram agregados a partir de uma soma simples. No caso do *label* 09 admitiu-se que 1/3 do valor registrado no arquivo ocorreu no dia n e os 2/3 restantes no dia $n+1$. Já o TMPA 3B42, teve os registros multiplicados por 3 antes da agregação (soma simples). Devido a sua especificidade, também no *label* 09 considerou-se que 83,3% do valor registrado ocorria no dia n , enquanto 16,6% no dia $n+1$. Por meio desses procedimentos todos os produtos de satélites utilizados foram compatibilizados temporalmente com os pluviômetros da ANA.

4.1.3.2 Interpolação espacial dos SRE

Como os satélites fornecem uma medida superficial de precipitação sobre uma determinada região, não é possível uma comparação direta com a medida pontual fornecida pelos pluviômetros. Nesse contexto, foi selecionado um método de *dowscaling* dos dados de satélite, objetivando-se: (i) transformar uma precipitação superficial média (satélites) em uma precipitação pontual; (ii) não alterar o valor da precipitação que é tomada como a de referência (pluviômetros); e (iii) interpolar a fonte de dados mais “completa”, visto que o desempenho desses algoritmos depende drasticamente do número de registros considerados (n.º de estações), o que é providenciado pelos produtos de satélite (número de falhas muito inferior aos dos pluviômetros, observando-se os critérios da análise preliminar).

O método adotado é o da “Interpolação bilinear ponderada” (BWI do inglês *bilinear weighted interpolation method*), conforme descrito e aplicado por Uddin *et al.* (2008) e outros autores em estudos similares (CHEN *et al.*, 2013; EBRAHIMI *et al.*, 2017; GAO; LIU, 2013; SAPIANO; ARKIN, 2009). A ideia central é interpolar os valores dos *pixels* de satélite sobre a estação pluviométrica considerando-se as distâncias entre as coordenadas geográficas dessa estação e dos *pixels* que a circundam.

Baseando-se na Figura 4.8, seleciona-se os *pixels* para a interpolação de forma que a estação pluviométrica sempre fique dentro das linhas pontilhadas que “ligam” os centros dos *pixels*. O encontro dos *pixels* é tomado como origem e assume as coordenadas (0,0). As coordenadas X_i, Y_i são as do local onde se deseja interpolar a chuva de satélite, nesse caso a localização da estação pluviométrica, e as coordenadas de X_1, Y_1 até a X_2, Y_2 são as coordenadas dos centros dos *pixels* adjacentes.

Inicialmente, calcula-se o “peso” (influência) na direção X e Y de cada *pixel* sobre a estação pluviométrica da seguinte forma:

$$S_X = \frac{X - X_1}{X_2 - X_1}$$

Equação 4.1

na qual:

X = coordenada horizontal da estação

X_1 = coordenada horizontal dos *pixels* à esquerda

X_2 = coordenada horizontal dos *pixels* à direita

S_X = ponderação no eixo horizontal

$$S_Y = \frac{Y - Y_1}{Y_2 - Y_1}$$

Equação 4.2

na qual:

Y = coordenada vertical da estação

Y_1 = coordenada vertical dos *pixels* superiores

Y_2 = coordenada vertical dos *pixels* inferiores

S_Y = ponderação no eixo vertical




Figura 4.8 – Visão gráfica do método BWI numa grade 2x2.

Fonte: Adaptado de Ebrahimi *et al.* (2017).

Considerando as informações acima, a precipitação sobre uma determinada estação é calculada da seguinte forma:

$$P_{X,Y} = (1 - S_X) \cdot (1 - S_Y) \cdot P_{X_1Y_1} + S_X \cdot (1 - S_Y) \cdot P_{X_2Y_1} + (1 - S_X) \cdot S_Y \cdot P_{X_1Y_2} + S_X \cdot S_Y \cdot P_{X_2Y_2}$$

Equação 4.3

na qual:

$P_{X,Y}$ = precipitação interpolada sobre a estação

S_X = ponderação no eixo horizontal

S_Y = ponderação no eixo vertical

$P_{X_iY_j}$ = precipitação dos quatro *pixels* adjacentes

Assim, quanto mais próximas as coordenadas X_i, Y_i do centro de algum pixel, mais influência (“peso”) esse pixel terá sobre o valor final da precipitação. Logo, o método BWI considera que há uma certa variabilidade da precipitação estimada pelo satélite dentro do *pixel*.

4.1.4 Análise comparativa dos produtos de satélite e *in situ*

A avaliação de desempenho dos produtos de satélite foi realizada a partir de métricas de chuva que são divididas aqui em estatísticas de ocorrência, conhecidas também por índices discretos ou categóricos e estatísticas quantitativas, sugeridas em estudos consoantes ao presente (BECK *et al.*, 2017, 2019; HUSSAIN *et al.*, 2018). Wilks (2011) e Ebert (2007) fazem uma descrição mais completa dos métodos estatísticos utilizados.

4.1.4.1 Estatísticas de ocorrência de chuva

Uma previsão dicotômica representa as seguintes situações: "sim, um evento acontecerá" ou "não, o evento não acontecerá". Previsão de chuva e neblina são exemplos comuns nessa categoria. Para algumas aplicações, um limiar pode ser especificado para separar "sim" e "não", por exemplo, chuvas diárias acima de 1mm (FALCK *et al.*, 2016), já outras metodologias segregam a amostra por faixas de classes de eventos (BAEZ-VILLANUEVA *et al.*, 2018).

Neste trabalho adotou-se a abordagem proposta e aplicada por Zambrano-Bigiarini *et al.* (2017), na qual os autores propõem uma adequação para a escala diária da classificação das intensidades de precipitação do Guia de Instrumentos Meteorológicos e Métodos de Observação da OMM (OMM, 2014). A partir dessa transformação, os autores sugerem que a tabela de contingência seja constituída a partir de classes de eventos, conforme descrito em reprodução literal na Tabela 4.5. Essa abordagem também foi adotada por Baez-Villanueva *et al.* (2018) e Acharya *et al.* (2019).

Tabela 4.5 – Proposta de classificação de eventos de chuva baseados na intensidade diária.

Classes de eventos	Intensidade (mm/dia)
Sem chuva	[0, 1)
Chuva leve	[1, 5)
Chuva moderada	[5, 20)
Chuva pesada	[20, 40)
Chuva extrema	≥ 40

Fonte: Adaptado de Zambrano-Bigiarini *et al.* (2017).

Para verificar esse tipo de previsão, elabora-se a tabela de contingência, conforme a Tabela 4.6, que contém a frequência dos possíveis eventos para as quatro combinações de concordância entre as observações de superfície (pluviômetros) e os dados estimados por satélite.

Tabela 4.6 – Tabela de contingência para categorizar as frequências de eventos.

		PLUVIÔMETROS		
		Sim	Não	TOTAL
SATÉLITE	Sim	a	b	$a+b$
	Não	c	d	$c+d$
TOTAL		$a+c$	$b+d$	$n=a+b+c+d$

Fonte: Wilks (2011) e Ebert (2007).

Essas combinações são denominadas de distribuição conjunta e encontram-se descritas abaixo:

- (a) acerto (*hit*): quando pluviômetro e o satélite registram a ocorrência de chuva pertencente a classe analisada;
- (b) alarme falso (*false alarm*): quando o satélite registra a ocorrência de chuva dentro da classe, em discordância com o pluviômetro;
- (c) falha (*miss*): quando o pluviômetro registra a ocorrência de chuva dentro da classe, e o satélite falha e não o registra na mesma classe;
- (d) correto negativo (*correct negatives*): quando ambos, satélite e pluviômetro, não registram a ocorrência de chuva dentro da classe determinada.

As somas das combinações (a+c; b+d; a+b e c+d) representam as frequências totais de ocorrências e de não ocorrências dos eventos (representadas nos lados inferior e direito da Tabela 4.6), isso é, as distribuições marginais. A tabela de contingência é uma maneira útil de ver quais tipos de erros ocorreram.

Um sistema de previsão perfeito produziria apenas acertos e corretos negativos, sem falhas ou alarmes falsos. Uma grande variedade de estatísticas discretas (categóricas) podem ser calculadas a partir dos elementos contidos na tabela de contingência, e relatam aspectos específicos do desempenho da estimativa. As métricas categóricas adotadas neste estudo estão descritas a seguir.

Probabilidade de detecção

A taxa de acerto ou probabilidade de detecção (POD, do inglês *probability of detection*) representa a fração de eventos chuvosos que foram corretamente identificados pelo produto de satélite, sendo representado pela Equação 4.4:

$$POD = \frac{a}{a + c}$$

Equação 4.4

na qual:

a = número de acertos

c = número de falhas

O POD é sensível ao acerto (a), mas ignora o número do alarme falso (b). Também se apresenta sensível à frequência climatológica do evento e identifica bem eventos raros. O valor de POD está na faixa de 0 e 1, e para uma pontuação perfeita o valor de POD deve ser igual a 1.

Razão de alarme falso

A razão de alarme falso (FAR, do inglês *false alarm ratio*) representa a fração de eventos identificados pela estimativa de chuva por satélite que não ocorreram de fato. Representa-se pela Equação 4.5:

$$FAR = \frac{b}{a + b}$$

Equação 4.5

na qual:

b = número de alarmes falsos

a = número de acertos

O FAR é sensível ao alarme falso, mas ignora a falha. Mostra-se sensível à frequência climatológica do evento e seu valor varia entre 0 e 1, obtendo-se valor igual à 0 para uma perfeita estimativa.

Viés da frequência

O viés da frequência (fBIAS, do inglês *frequency bias*) mede a razão entre a frequência dos eventos previstos pelos satélites e a frequência dos eventos observados pelos pluviômetros, sendo representado pela Equação 4.6:

$$fBIAS = \frac{a + b}{a + c}$$

Equação 4.6

na qual:

a = número de acertos

b = número de alarmes falsos

c = número de falhas

Indica se o satélite tem uma tendência a subestimar ($fBIAS < 1$) ou superestimar ($fBIAS > 1$) os eventos chuvosos para uma determinada classe. Para uma perfeita detecção desses eventos chuvosos, o valor de fBIAS é igual a 1.

4.1.4.2 Estatísticas quantitativas de chuva

As estatísticas quantitativas de chuva avaliam as diferenças entre as intensidades das observações dos pluviômetros (P) e as estimativas dos produtos de satélites (S). Conforme

apresentado a seguir, \bar{P} e \bar{S} representam as médias aritméticas das observações de pluviômetros e das estimativas dos produtos de satélites, respectivamente. As métricas empregadas nas análises, a exemplo das anteriores, foram selecionadas considerando-se publicações com objetivos consoantes ao presente (BAEZ-VILLANUEVA *et al.*, 2018; DAWSON; ABRAHART; SEE, 2007, 2010; ZAMBRANO-BIGIARINI *et al.*, 2017).

Erro médio absoluto

O erro médio absoluto (MAE, do inglês *mean absolute error*) registra, em unidades da variável, o nível de concordância geral entre os conjuntos de dados observados e modelados. É uma métrica não negativa que não possui um limite superior e, para um modelo perfeito, o resultado seria zero.

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - S_i|$$

Equação 4.7

na qual:

n = tamanho da amostra

P_i = precipitação pluviométrica

S_i = estimativa de precipitação por satélite

O MAE não fornece informações sobre subestimação ou superestimação dos valores estimados em relação aos observados. Não é ponderada para diferenças de baixa e alta magnitudes, mas avalia todos os desvios dos valores observados de maneira igual e independente do sinal.

Coeficiente de eficiência Kling-Gupta modificado

O coeficiente Kling-Gupta modificado (KGE', do inglês *modified Kling-Gupta efficiency statistic*) representa um índice para comparar as observações dos pluviômetros com os dados estimados dos satélites em termos da correlação linear (r), do viés (β) e da variabilidade (γ) entre ambos. As equações abaixo representam o índice e seus três componentes individuais:

$$KGE' = 1 - \sqrt{(r - 1)^2 + (\beta - 1)^2 + (\gamma - 1)^2}$$

Equação 4.8

na qual:

r = coeficiente de correlação linear de Pearson

β = razão entre as médias

γ = razão entre os coeficientes de variação

$$r = \frac{\sum_{i=1}^n (S_i - \bar{S}_i) \cdot (P_i - \bar{P}_i)}{\sqrt{\sum_{i=1}^n (S_i - \bar{S}_i)^2} \cdot \sqrt{\sum_{i=1}^n (P_i - \bar{P}_i)^2}}$$

Equação 4.9

na qual:

n = tamanho da amostra

P_i = precipitação pluviométrica

\bar{P}_i = média da precipitação pluviométrica

S_i = estimativa de precipitação por satélite

\bar{S}_i = média da estimativa de precipitação por satélite

$$\beta = \frac{\mu_S}{\mu_P}$$

Equação 4.10

na qual:

μ_S = precipitação média do produto de satélite

μ_P = precipitação média pluviométrica

$$\gamma = \frac{CV_S}{CV_P} = \frac{\sigma_S / \mu_S}{\sigma_P / \mu_P}$$

Equação 4.11

na qual:

CV_S = coeficiente de variação dos produtos de satélite

CV_P = coeficiente de variação dos pluviômetros

σ_S = desvio padrão dos produtos de satélite

σ_P = desvio padrão dos pluviômetros

μ_S = precipitação média do produto de satélite

μ_P = precipitação média pluviométrica

O KGE' reproduz a dinâmica temporal entre os dados de superfície e dos satélites (medida pelo r), assim como a razão entre volume estimado sobre o volume observado e a razão entre a variabilidade dos dados de satélite e os dados de superfície (medida pelo β e γ , respectivamente). O valor ideal para o KGE', r , β e γ é 1.

4.2 Etapa 2 – Aplicação de técnicas para correção de viés

Nesta etapa, são empregados dois métodos com o intuito de reduzir o viés dos produtos de satélite em relação aos registros dos pluviômetros nas escalas diária e mensal. Ambos os métodos são técnicas que buscam ajustar uma função h que mapeia a variável modelada de tal forma que seu histograma seja equivalente ao histograma da variável observada. Neste estudo, as variáveis observadas são os registros dos pluviômetros (P) e as modeladas são as estimativas de precipitação por satélite (S). Em linhas gerais, essa transformação pode ser formulada como:

$$P = f(S)$$

Equação 4.12

na qual:

P = precipitação pluviométrica

f = função de transformação

S = estimativa de precipitação por satélite

As variáveis P e S são denominadas resposta e explicativa, respectivamente. Nesse caso, a estimativa de satélite tenta explicar a precipitação observada em superfície. Há várias formas de se estimar a função de transferência (f) (LAFON *et al.*, 2013). Os métodos aplicados nesse estudo se basearam na proposta de Gudmundsson *et al.* (2012).

4.2.1 Regressão linear simples

Na primeira técnica, é realizado um ajuste de modelo linear por meio de uma relação quantil-quantil. Propõe-se aqui uma regressão linear simples de primeira ordem, dada pela equação:

$$P_{cor} = a + b \cdot S$$

Equação 4.13

na qual:

P_{cor} = precipitação corrigida

S = estimativa de precipitação por satélite

a e b = parâmetros

A estimativa dos parâmetros a e b é realizada através da função `lm` da biblioteca `stats_v3.7.0` da linguagem R (<https://stat.ethz.ch/R-manual/R-devel/library/stats/html/lm.html>). Tal função aplica o Método dos Mínimos Quadrados, o qual minimiza a soma dos quadrados dos resíduos – as diferenças entre os dados observados (P) e os dados estimados (S) –, de forma a maximizar o grau de ajuste do modelo aos dados observados. Após o ajuste, aplica-se a Equação 4.13 nos

dados da estimativa de satélite, com o intuito de aproximar seus valores aos valores dos pluviômetros, corrigindo-os.

4.2.2 Mapeamento de quantis

A correção de viés por mapeamento de quantis é procedida da seguinte forma: na Figura 4.9-a temos uma função densidade de probabilidade (fdp) ajustada a cada histograma da série de dados de chuva. Considera-se que, o histograma ajustado com uma curva sólida é representativo da precipitação modelada (S) sobre uma dada estação, enquanto o histograma ajustado com uma curva tracejada é representativo da precipitação observada (P) no mesmo local. Então, calcula-se a função de distribuição acumulada (FDA) para cada variável, e associa-se cada variável modelada (S) ao valor da variável observada (P), equiparando as suas probabilidades de não excedência da seguinte forma: $FDA_S(S) = FDA_P(P)$. Tal procedimento está ilustrado na Figura 4.9-b.

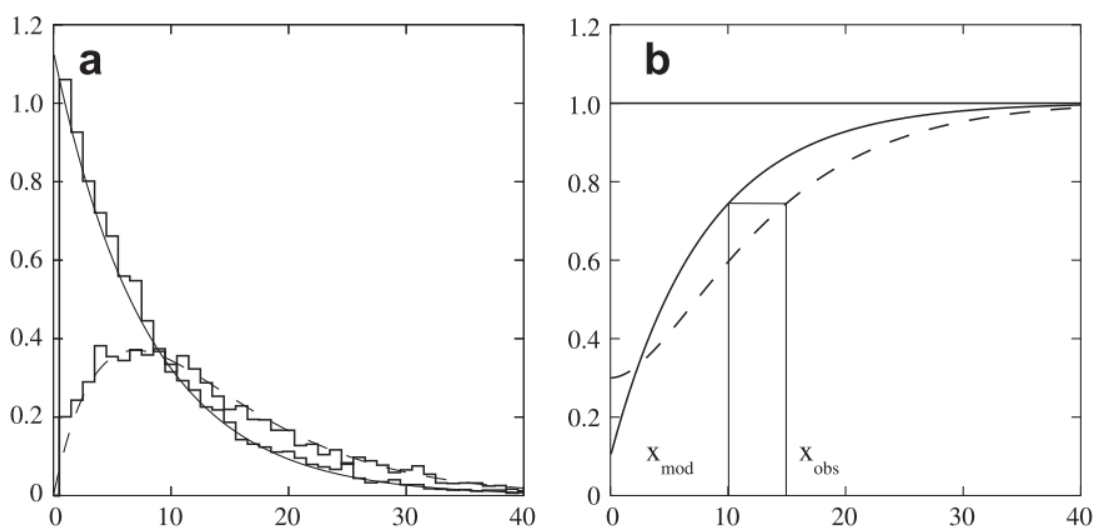


Figura 4.9 – Exemplo gráfico da técnica mapeamento de quantis.

Quando as distribuições das variáveis de interesse são conhecidas, essa transformação estatística é conhecida por transformação derivada de distribuição teórica, e é definida pela Equação 4.14, conforme descrito a seguir:

$$P_{cor} = F_P^{-1}(F_S(S)) \quad \text{Equação 4.14}$$

na qual:

P_{cor} = precipitação corrigida

S = estimativa de precipitação por satélite

F_S = FDA de S

F_P^{-1} = FDA inversa ou função de quantis de P

A Equação 4.14 retorna a “correção” da variável S de forma que ela se aproxime de P. Entretanto, para a utilização dessa abordagem necessita-se conhecer as distribuições teóricas das variáveis modeladas e observadas para o ajuste dos parâmetros dessas distribuições. Por isso, adotou-se a abordagem não paramétrica dessa técnica.

Para esse procedimento, foi utilizada a biblioteca *Statistical Transformations for Post-Processing Climate Model Output* (qmap), em linguagem R (<https://cran.r-project.org/web/packages/qmap/index.html>).

A biblioteca qmap estima as FDAs empíricas a partir de tabelas de percentis das precipitações não nulas (acima de zero) dos dados observados (P) e modelados (S). O quantil para uma determinada intensidade de chuva é estimado por interpolação linear entre os percentis. Nos casos em que a intensidade da chuva modelada for superior ao maior quantil da distribuição histórica, a biblioteca adota a correção corresponde ao maior quantil disponível (GUDMUNDSSON *et al.*, 2012; POTTER *et al.*, 2019).

Para verificar a eficiência de ambas as técnicas, os modelos propostos foram ajustados (treinados) utilizando-se 50% dos dados disponíveis (período de calibração). Posteriormente, as relações foram avaliadas (testados) com os 50% dos dados restantes (período de validação). Então, as métricas MAE e KGE' foram recalculadas, a partir dos dados brutos de satélite (sem correção), dos valores “corrigidos” e de pluviômetros, para o período de validação.

5. RESULTADOS E DISCUSSÃO

Os resultados, observando-se os objetivos propostos, estão apresentados conforme a metodologia proposta:

- (i) verificação do desempenho dos produtos de satélite no tocante à identificação de eventos (tabela de contingência) e de sua acurácia, nas escalas temporal diária, mensal e anual;
- (ii) avaliação da eficiência das técnicas de correção de viés aplicadas aos produtos de satélite.

Na Tabela 5.1 o número total de estações pluviométricas e de registros de precipitação da série histórica de dados, em função da escala temporal, estão sumariados.

Tabela 5.1 – Quantitativo de dados utilizados por escala temporal.

Escala temporal	Número total de estações (N)	Número total de registros (n_e)
Diária	166	772.737
Mensal	166	25.404
Anual	143	868

Apesar do número elevado de registros, nem todas as séries das estações pluviométricas possuem concomitância entre si. Cada produto de satélite, no entanto, possui um registro correspondente de pluviômetro, observando-se as escalas temporais avaliadas. Evidentemente, a redução nos quantitativos nas escalas mensal e anual deve-se à agregação dos dados diários e aos critérios empregados durante a análise preliminar

5.1 Avaliação de desempenho dos produtos de satélite

5.1.1 Desempenho na escala diária

A Tabela 5.2 apresenta as estatísticas descritivas das séries temporais analisadas. As medidas de tendência central (mediana e média) apresentam ordem de grandeza similares, assim como o coeficiente de variação. Contudo, os pluviômetros apresentam desvio padrão superior aos produtos de satélite (maior dispersão em relação a média dos registros).

Tabela 5.2 – Estatísticas descritivas dos dados de chuva diários para todas as séries.

Estatísticas descritivas	Pluviômetros ANA	TMPA 3B42	CMORPH	PERSIANN
Mínimo (mm/dia)	0	0	0	0
Máximo (mm/dia)	219	191	157	242
Mediana (mm/dia)	0	0	0	0
Média (mm/dia)	3,7	3,9	3,3	3,4
Desvio padrão (mm/dia)	10,1	8,7	7,7	7,8
Coeficiente de variação	2,7	2,2	2,3	2,3

Desempenho em relação aos índices categóricos

A Tabela 5.3 apresenta o percentual de dados diários por classes de eventos considerada. Como esperado, a maioria dos registros concentram-se na classe “Sem chuva”. A porcentagem de registros é semelhante para todos SRE, independentemente da classe. No entanto, somente para aquelas com taxas superiores ou iguais a 20 mm/dia, os percentuais são semelhantes aos dos pluviômetros. Nesse contexto, os resultados sugerem que, apesar de mensurarem a mesma

variável hidrológica, existem diferenças significativas no tocante a intensidade dos eventos identificados.

Tabela 5.3 – Distribuição dos dados diários em classes de eventos.

Classes de eventos diários (mm/dia)	Pluviômetros ANA	TMPA 3B42	CMORPH	PERSIANN
*[0,1) ou “Sem chuva”	75%	65%	67%	67%
[1,5) ou chuva leve	7%	13%	14%	13%
[5,20) ou chuva moderada	11%	16%	14%	15%
[20,40) ou chuva pesada	5%	5%	4%	4%
≥ 40 ou chuva extrema	2%	1%	1%	1%

* “[” representa maior ou igual a limite inferior da classe, enquanto “) ” representa menor do que o limite superior.

É válido destacar que as métricas na escala diária foram calculadas por estação. Os valores indicados nas tabelas que as descrevem são as medianas de cada classe e/ou produto avaliado.

A Figura 5.1 apresenta a probabilidade de detecção de cada produto de satélite por classes de evento. Analisando a referida tabela, nota-se uma discrepância entre os valores do POD da classe “sem chuva” frente as demais. Essa detecção próxima do “ótimo” revela que todos os produtos de satélite foram capazes de identificar a ocorrência ou não de chuva. Todos os produtos de satélites obtiveram um valor de POD próximos nessa classe ($POD > 0,8$), e o produto CMORPH obteve uma maior capacidade de detecção quando comparado aos demais.




Figura 5.1 – Mediana da métrica POD de todos os produtos por classes de eventos.

Contudo, nas outras classes de eventos, os produtos apresentaram valores de POD inferiores a 0,5. De forma geral, quando chove, os produtos identificam melhor as chuvas classificadas como moderadas ([5 a 20) mm/dia). Todas as estimativas de satélite tiveram baixo desempenho de detecção quando da ocorrência de eventos categorizados como extremos (≥ 40 mm/dia; $POD < 0,2$). Individualmente, o produto CMORPH apresentou POD superior aos demais para intensidades diárias de chuva inferiores a 5 mm/dia. Para intensidades superiores a esse limite, o produto TMPA mostrou-se superior. O produto PERSIANN, em especial, demonstrou menor capacidade de detecção quando da ocorrência de chuva (independente da classe).

A Figura 5.2 mostra que os resultados da métrica razão de alarme falso apresentam consistência com a métrica POD. Para a classe de eventos “sem chuva”, todos os produtos apresentaram um desempenho próximo do valor “ótimo” da métrica ($FAR < 0,1$). Por outro lado, para as demais classes, todos os produtos apresentaram valores de FAR entre 0,6 e 0,9. O produto CMORPH apresentou os menores valores de FAR para as classes acima de 1 mm/dia. O produto TMPA apresentou o menor FAR na classe “sem chuva”, e o produto PERSIANN foi inferior aos demais em todas as classes de eventos.

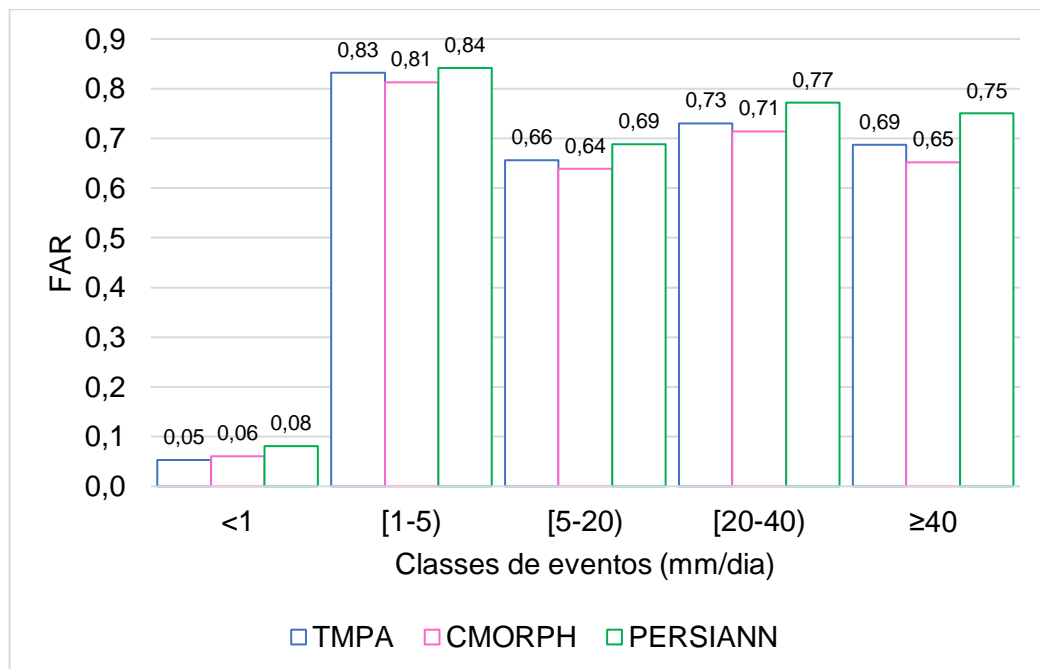


Figura 5.2 – Mediana da métrica FAR de todos os produtos por classes de eventos.

Os resultados apresentados pelas métricas POD e FAR mostram que os produtos de satélite possuem elevada capacidade de identificar a ocorrência ou não de chuva. Entretanto, as

intensidades estimadas a partir das informações de satélite, em sua maioria, diverge dos valores registrados pelos pluviômetros, observando-se os limites das classes empregadas.

De fato, quando pluviômetros e satélites observam um mesmo evento chuvoso, as intensidades registradas desses eventos são diferentes devido as particularidades metodológicas que são inerentes às próprias técnicas de medição. Os sensores IV (fonte primária do PERSIANN), por exemplo, inferem precipitação na superfície baseando-se na temperatura fria do topo de nuvens altas, porém a nuvem observada pode ser do tipo *cirrus*, a qual é fria, mas não gera precipitação. Ademais, nuvens do tipo *nimbostratus* precipitantes são baixas e aparentam possuir o topo “quente” para os sensores IV. Aliás, outras camadas de nuvens, entre a observada pelo satélite e a superfície, é que de fato podem ser responsáveis pela precipitação.

Os sensores MO (fonte primária do TMPA e CMORPH) medem uma taxa de chuva baseando-se da quantidade de cristais de gelo nas nuvens. Porém, devido a esses sensores serem instalados em satélites LEO, eles registram um momento instantâneo do evento, e não acompanham a evolução do mesmo. Logo, não necessariamente todos os cristais de gelo tornam-se precipitação líquida instantaneamente no mesmo local. Nuvens com pouca quantidade de cristais de gelo são um problema para esses sensores também. Enfim, ambos os sensores não medem precipitação na superfície em si, mas características das nuvens que podem produzir precipitação.

As medianas do viés da frequência de todos os produtos por classe de eventos estão apresentadas na Figura 5.3. Todos os produtos subestimam a frequência de eventos em relação aos pluviômetros nas classes sem chuva (< 1 mm/dia) e chuvas extremas (≥ 40 mm/dia). Nas classes de chuvas leves e moderadas os mesmos superestimam a frequência de eventos que de fato ocorreram. Já na classe de chuvas pesadas ($[20, 40)$ mm/dia), o TMPA está em consonância com os pluviômetros, ao contrário dos produtos CMORPH e PERSIANN, que subestimam eventos nessa classe. Os gráficos dos *box plots* dos índices categóricos por classes de eventos estão na seção APÊNDICES.




Figura 5.3 – Mediana da métrica fBIAS de todos os produtos por classes de eventos.

Os resultados da métrica fBIAS realçam as diferenças entre as escalas espaciais entre pluviômetros e satélites. Os pluviômetros realizam uma medida pontual de chuva e os produtos realizam uma estimativa média de precipitação numa área de aproximadamente 625 km². Portanto, vários eventos de menor extensão espacial detectados pelos sensores não são registrados pelos pluviômetros. No caso de eventos convectivos, em especial, espera-se que a diferença seja expressiva. Infere-se que parte das diferenças observadas no tocante as chuvas leves e moderadas sejam motivadas por esse fato.

A avaliação do desempenho dos produtos para diferentes intensidades de precipitação resultou em valores baixos para maioria dos índices categóricos. Isso também se deve, em parte, aos exigentes critérios de classificação empregados para construção da tabela de contingência: utilizou-se cinco classes de intensidades de precipitação em vez das típicas “chuva” e “sem chuva” de outros estudos (BECK *et al.*, 2017; GADELHA *et al.*, 2019; TAN; SANTO, 2018). Todos os SRE foram capazes de identificar com boa precisão a ocorrência de eventos “sem chuva”, mas durante os dias chuvosos eles apresentaram uma baixa habilidade em fornecer uma classificação precisa das intensidades de precipitação.

Perante a métrica fBIAS, e de forma similar as outras métricas categóricas (POD e FAR), cada produto obteve desempenho superior ao outro dependendo da classe de eventos. Os resultados dos índices categóricos mostram que, não há entre os produtos analisados, um que possua

desempenho superior perante todas as classes de eventos. Entretanto, para a maiorias das análises o produto TMPA foi superior, seguido pelo produto CMORPH.

Desempenho em relação as métricas contínuas

O desempenho diário dos produtos de satélite, de acordo com as métricas de acurácia erro médio absoluto (MAE) e coeficiente de eficiência de Kling-Gupta modificado (KGE'), foi avaliado de forma similar as métricas categóricas. A figura Figura 5.4 mostra os *box plots* da métrica MAE por estação. O produto CMORPH apresentou uma mediana de 3,2 mm/dia, resultado levemente inferior aos dos outros produtos (TMPA e PERSIANN apresentaram medianas iguais a 3,4 mm/dia e 3,7 mm/dia, respectivamente).

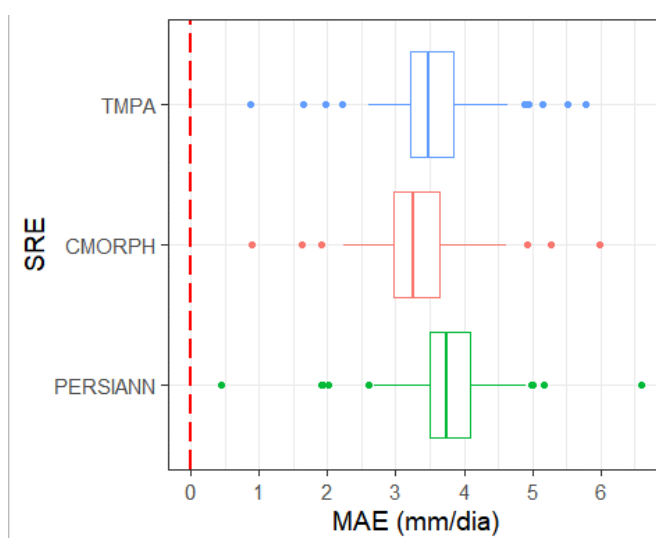


Figura 5.4 – *Box plots* da métrica MAE de todos os produtos na escala diária por estação.

Avaliou-se o desempenho dos produtos diante da métrica MAE por classes de eventos (Figura 5.5). O erro por classes de eventos se mostrou elevado, em torno de 100% para todos os produtos, fato que pode ser explicado pelas as diferenças como os medidores (pluviômetros e satélites) interpretam o fenômeno.




Figura 5.5 – Medianas da métrica MAE de todos os produtos de satélite por classe de eventos.

Conforme visto nos resultados das métricas categóricas (POD, FAR e fBIAS), nenhum produto de satélite obteve desempenho superior a outro em todas as classes de eventos. O produto CMORPH obteve desempenho superior para chuvas menores que 20 mm/dia. Já o produto TMPA obteve desempenho superior para chuvas pesadas e extremas. Novamente, de um modo geral, o produto PERSIANN obteve desempenho inferior diante aos demais produtos analisados.

Considerando a métrica KGE' por estação, os produtos TMPA e CMORPH apresentaram medianas similares ($KGE' \approx 0,54$), enquanto o produto PERSIANN apresentou resultado expressivamente inferior ($KGE' \approx 0,41$) (Figura 5.6).

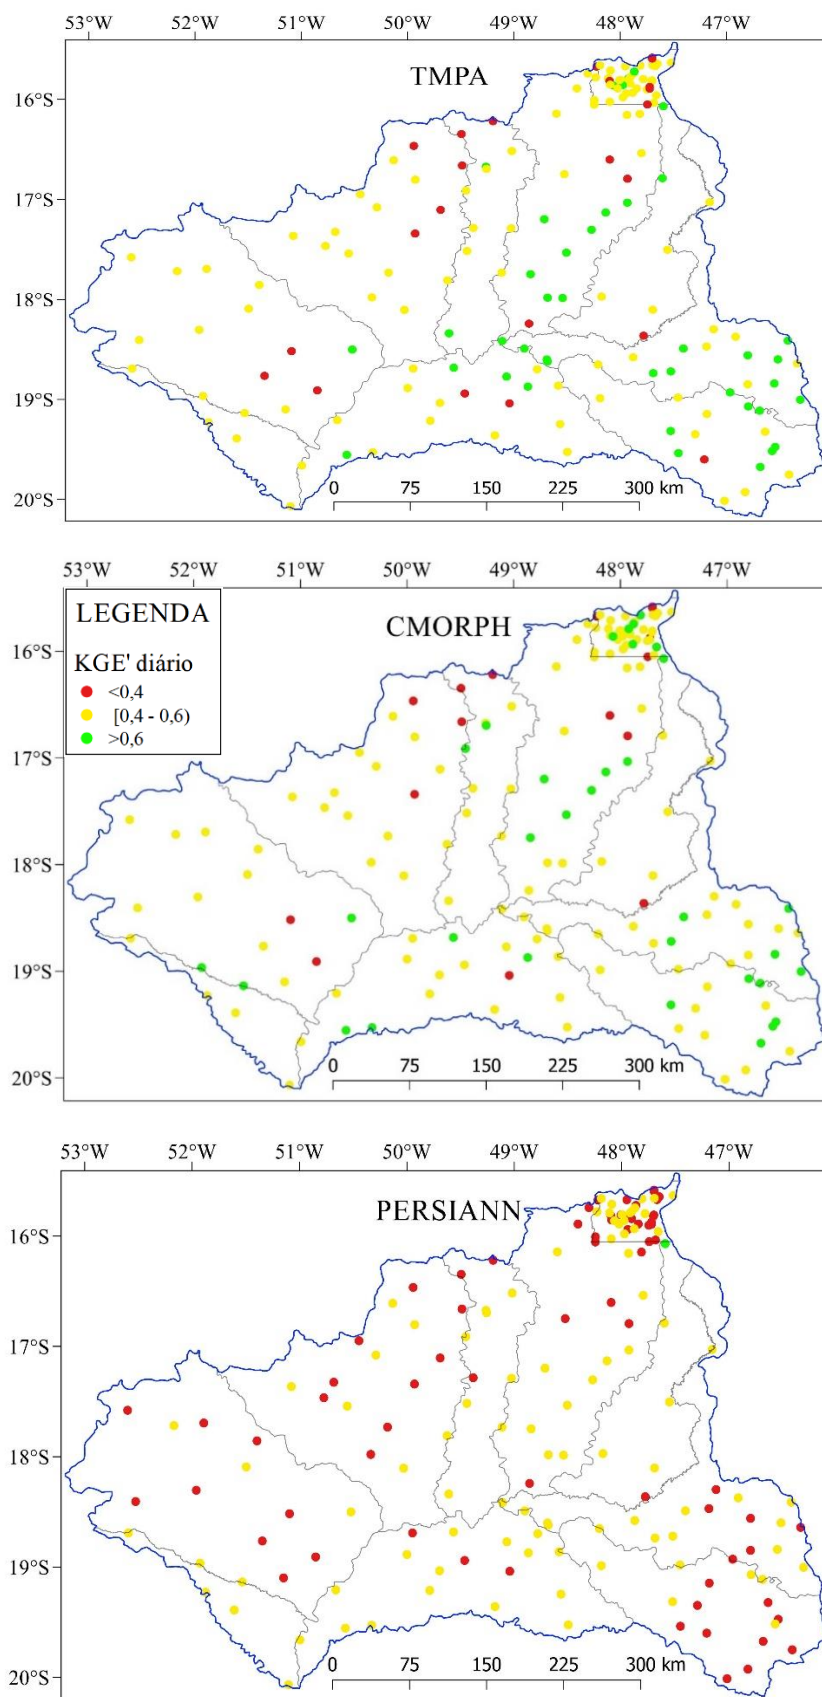


Figura 5.6 – Mapas da métrica KGE' na escala diária para todos os produtos de satélite.
(Obs.: legenda no mapa central).

As medianas das componentes individuais do KGE' de todos os produtos estão apresentadas na Tabela 5.4. O coeficiente de correlação linear de Pearson obteve resultados inferiores as outras componentes do KGE' ($r < 0,61$). Isso revela, em acordo com os estudos de Baez-Villanueva *et al.* (2018) e Zambrano-Bigiarini *et al.* (2017), que os produtos avaliados não conseguem reproduzir com eficiência a dinâmica temporal diária observada pelas estações pluviométricas.

Tabela 5.4 – Medianas das componentes da métrica KGE' diária de todos os produtos de satélite.

Produtos de satélite	Componentes KGE'		
	r	β	γ
TMPA	0,60	1,06	0,81
CMORPH	0,59	0,89	0,86
PERSIANN	0,47	0,90	0,85

O produto TMPA obteve o melhor desempenho ao representar o volume médio diário de chuva registrado nos pluviômetros ($\beta = 1,06$). Já os demais produtos subestimaram esse volume ($\beta < 0,9$). No tocante à variabilidade das intensidades registradas pelos pluviômetros, todos os produtos a subestimaram ($\gamma < 0,8$). Os *box plots* das componentes da KGE' por estação na escala diária estão na seção APÊNDICES.

Os resultados das métricas MAE e KGE' por estação demonstram que, reiteradamente o produto PERSIANN obteve desempenho abaixo dos demais produtos. Dentre outros fatores, isso pode advir do algoritmo PERSIANN utilizar como fonte primária informações de sensores do tipo IV-Vis, os quais fornecem medidas mais indiretas de precipitação do que os sensores MO.

A Tabela 5.5 mostra as medianas das componentes do KGE' por classes de chuvas de todos os produtos de satélite. Nessa abordagem, nota-se que, em algumas classes, os valores de cada componente se distanciam de forma significativa de seu melhor valor. Independente da classe e em todos os produtos, nota-se uma baixa correlação linear desses com a série registrada pelos pluviômetros ($r < 0,2$). De forma sumária, os produtos de satélite analisados apresentaram baixa “concordância” com os pluviômetros, registrando intensidades de chuva significativamente díspares durante o mesmo intervalo de tempo.

Tabela 5.5 – Medianas das componentes KGE' por classes de eventos de todos os produtos de satélite.

Classes de eventos (mm/dia)	TMPA			CMORPH			PERSIANN		
	r	β	γ	r	β	γ	r	β	γ
[0,1) ou sem chuva	0,16	83,7	0,51	0,15	68,3	0,53	0,13	83,5	0,57
[1,5)	0,10	2,58	2,72	0,10	2,08	2,93	0,07	2,27	2,99
[5,20)	0,17	1,03	2,51	0,16	0,86	2,66	0,12	0,84	2,88
[20,40)	0,12	0,62	4,00	0,12	0,54	4,31	0,10	0,45	4,74
≥ 40	0,20	0,45	2,53	0,19	0,40	2,64	0,12	0,31	2,97

As informações fornecidas pela componente β complementam os resultados da métrica MAE por classes de eventos (Figura 5.5). Nas classes para chuvas menores que 5 mm/dia, todos os produtos avaliados superestimam as intensidades das chuvas em relação aos registros em superfície. Nas classes de chuvas moderadas, todos os produtos subestimam o volume diário de chuvas registradas pelos pluviômetros, exceto o produto TMPA. Para chuvas iguais e maiores que 20 mm/dia, todos os produtos subestimam as intensidades registradas pelos pluviômetros.

A razão entre os coeficientes de variação dos produtos de satélite e dos pluviômetros (γ) mostra que, para a classe “sem chuva”, os produtos de satélite possuem menor dispersão das intensidades de chuva do que os pluviômetros. Isso pode ser explicado pela dimensão (tamanho) da faixa de valores dessa classe (1 unidade), a qual é inferior as demais, restringindo a amplitude dos coeficientes de variação. Em contraposição, as medianas descritas na Tabela 5.4, para as demais classes, os pluviômetros possuem coeficientes de variação inferiores aos produtos de satélite. Isso indica que a variabilidade das intensidades de chuva estimada pelos produtos de satélite por classes de eventos é bastante dispare daquela mensurada pelos pluviômetros.

Como as diferenças se mostraram elevadas perante todas as métricas e abordagens analisadas, e em conformidade com outros estudos (DARAND; AMANOLLAHI; ZANDKARIMI, 2017; MA *et al.*, 2018; YIN *et al.*, 2008), avaliou-se a hipótese de efeitos orográficos na bacia do Paranaíba terem influenciado o desempenho dos SRE. Na maior parte das análises na escala diária, o produto PERSIANN obteve sistematicamente resultados mais distantes dos melhores valores por métrica aos demais produtos. Ainda assim, não é evidente que as diferenças estejam associadas ao relevo da bacia (Figura 5.7).

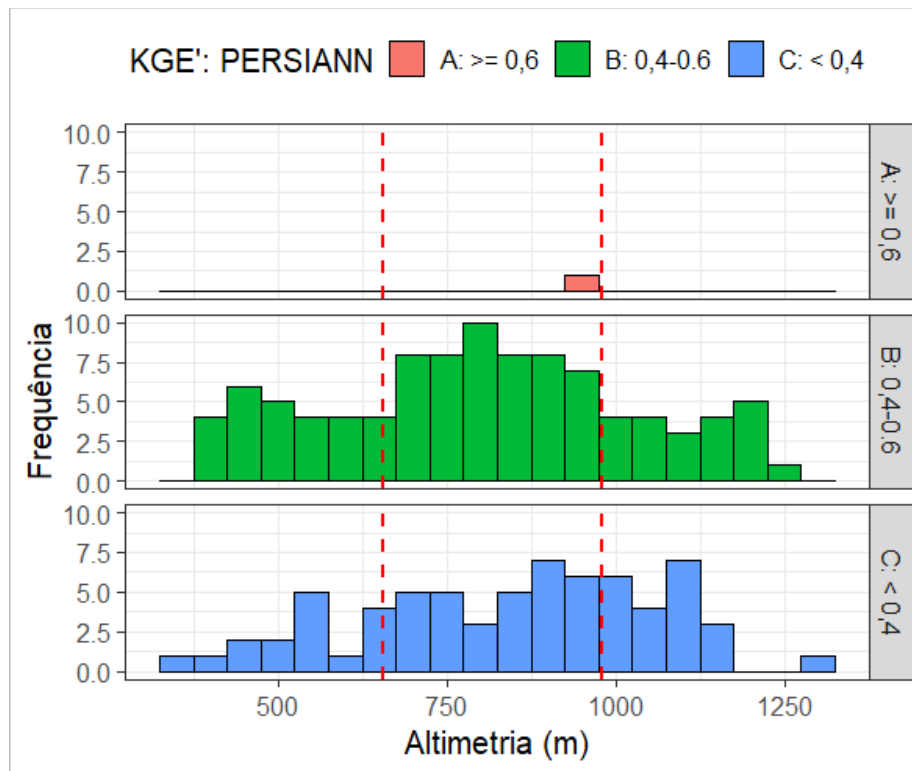
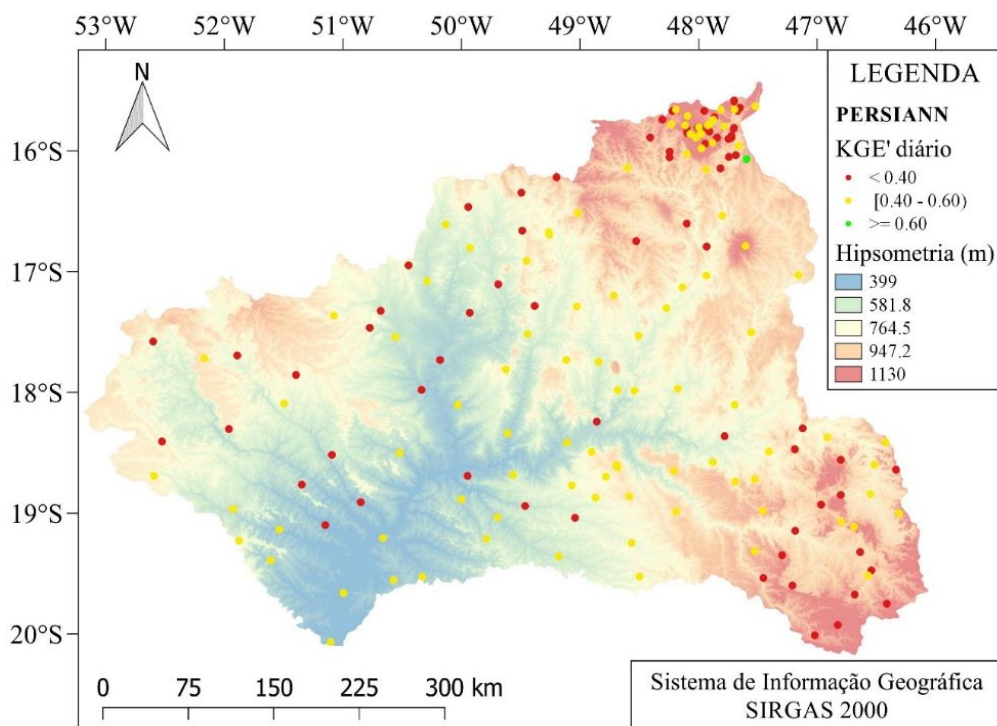


Figura 5.7 – Mapa de localização das estações sobre a hipsometria da bacia do rio Paraíba e histograma da altimetria da métrica KGE' por estação para o produto PERSIANN.

Caso os erros estivessem associados ao relevo, provavelmente, observar-se-ia uma concentração da frequência de valores similares de KGE' em uma determinada faixa de altimetria da bacia. O KGE' foi empregado por permitir uma análise comparativa

pormenorizada. Os resultados dos produtos TMPA e CMORPH revelaram resultados similares e estão apresentados na seção APÊNDICES.

De forma sumária, os resultados das medianas diárias de todas as métricas de acurácia por estação estão exibidos na Tabela 5.6. Em consonância com as métricas categóricas, esses resultados realçam que os valores das intensidades de precipitação entre os dados dos pluviômetros e os SRE exibem elevadas diferenças.

Tabela 5.6 – Medianas das métricas de acurácia de todos os SRE analisados na escala diária.

Métricas de acurácia	Produtos de satélite (SRE)		
	TRMM	CMORPH	PERSIANN
MAE (mm/dia)	3,48	3,25	3,73
KGE'	0,54	0,54	0,41
KGE': r	0,60	0,59	0,47
KGE': β	1,06	0,89	0,90
KGE': γ	0,81	0,86	0,85

5.1.2 Desempenho na escala mensal

Na escala mensal foram analisados os desempenhos dos produtos de satélite por meio das métricas de acurácia MAE e KGE' em três abordagens: por estação, por UGHs e por mês.

A Tabela 5.7 apresenta as estatísticas descritivas das séries mensais analisadas. As estatísticas apresentam ordem de grandeza semelhantes (independente do equipamento), observando-se a diferença entre valores máximos das séries.

Tabela 5.7 – Estatísticas descritivas para a série de dados mensais por estação pluviométrica para todos os medidores.

Estatísticas descritivas	Pluviômetros ANA	TMPA 3B42	CMORPH	PERSIANN
Mínimo (mm/mês)	0	0	0	0
Máximo (mm/mês)	811	616	533	940
Mediana (mm/mês)	77	86	73	74
Média (mm/mês)	113	120	101	102
Desvio padrão (mm/mês)	115	116	98	105
Coefficiente de variação	1,02	0,96	0,97	1,03

Os produtos de satélite apresentaram um MAE superiores a 29 mm/mês, em consonância com outros estudos (DINKU *et al.*, 2018; LIU, 2015) (Figura 5.8). O produto TMPA apresentou a menor mediana MAE (29,8 mm/mês), seguido pelo produto CMORPH, e posteriormente pelo PERSIANN, cujas medianas foram iguais a 30,9 e 40,2 mm/mês, respectivamente.

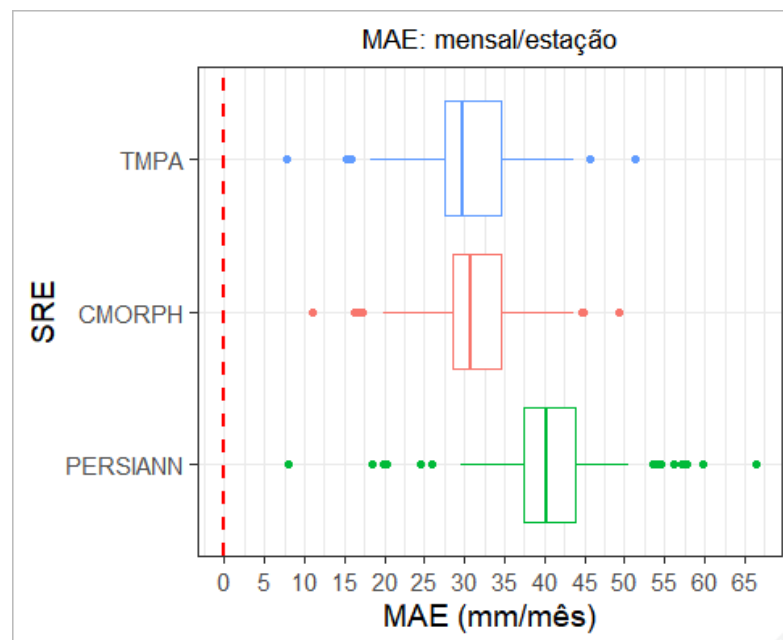


Figura 5.8 – *Box plots* da métrica MAE mensal por estação para todos os SRE.

A Figura 5.9 apresenta os *box plots* da métrica KGE' e de suas componentes na escala mensal. Assim como reportado por outros estudos (BEAUFORT; GIBIER; PALANY, 2019; HONG *et al.*, 2018), todos os produtos de satélite apresentam desempenho superior (em relação a escala diária) na escala mensal. De certa forma, espera-se que quanto maior o período de acumulação da chuva para análise, maior a chance de que os algoritmos gerem valores próximos aos registrados pelos pluviômetros. O TMPA obteve desempenho superior ($KGE'_{\text{mediana}} \approx 0,88$) aos demais. O produto PERSIANN, novamente, apresentou um desempenho inferior aos demais produtos analisados ($KGE'_{\text{mediana}} \approx 0,79$).

Em relação às componentes do KGE' na escala mensal, é válido destacar a correlação linear. O seu valor elevou-se para todos os produtos (r sempre superior a 0,75) em relação a escala diária. Nesse contexto, pode-se inferir que ao agregar as estimativas os erros temporais se compensam, aproximando os acumulados mensais registrados nos pluviômetros às estimativas de satélite.

Em termos de acumulados mensais, o produto TMPA superestima as médias mensais registradas pelos pluviômetros (mediana $\beta \approx 1,07$). Os produtos CMORPH (mediana $\beta \approx 0,89$) e PERSIANN (mediana $\beta \approx 0,90$) indicam uma subestimativa dos volumes mensais. Em relação à escala diária, não houve uma melhoria expressiva dessa componente. Individualmente, o TMPA apresentou resultados mais próximos do melhor valor.

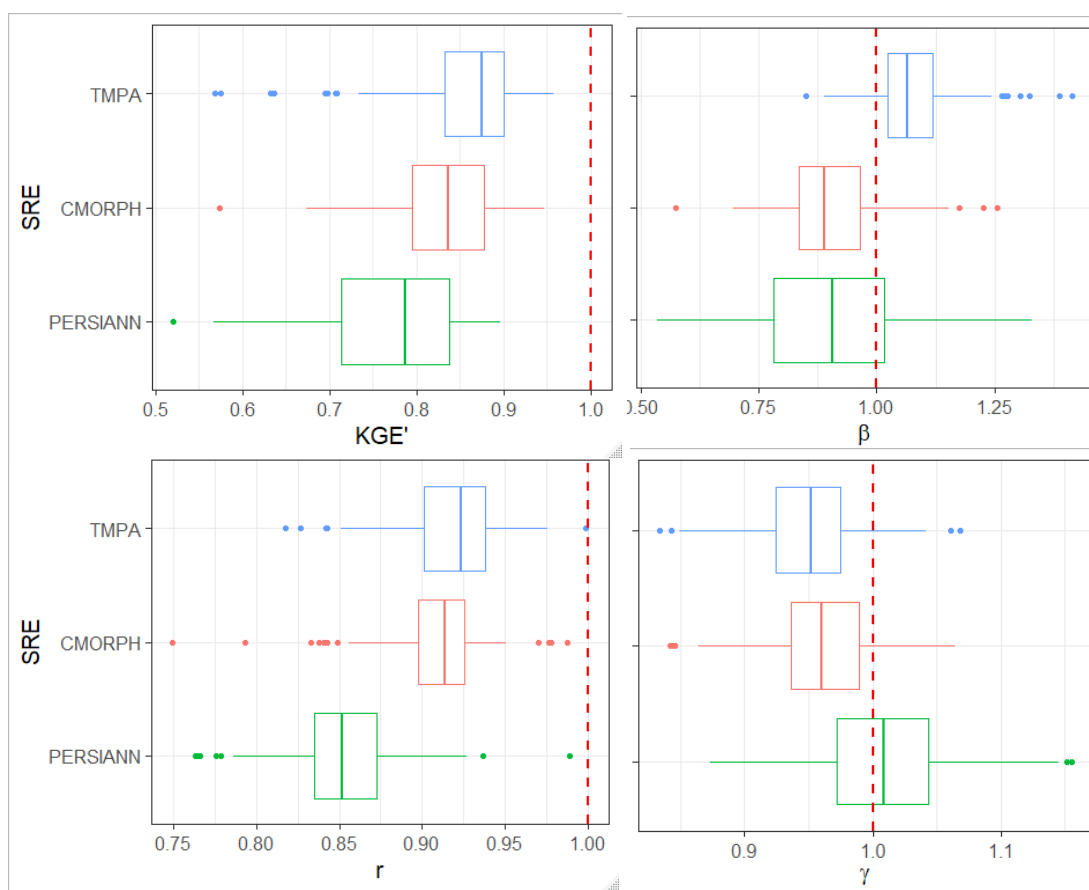


Figura 5.9 – Box plots da métrica KGE' e suas componentes (r , β e γ) mensais por estação para cada SRE.

A representatividade entre a dispersão das intensidades de precipitação dos produtos em relação aos pluviômetros na escala mensal se sobressaiu aos resultados dessa componente na escala diária (Tabela 5.6). Surpreendentemente, o produto PERSIANN desempenhou de forma eminente (mediana $\gamma \approx 1,01$). Já o CMORPH (mediana $\gamma \approx 0,96$) e o TMPA (mediana $\gamma \approx 0,95$) apresentaram performances semelhantes.

Para análise por Unidades de Gestão Hídrica (UGH) procedeu-se da seguinte forma: agrupou-se as estações pertencentes a determinada UGH (Figura 5.10) e, então, computou-se as métricas de acurácia para esses grupos. O objetivo é verificar o desempenho dos produtos sobre uma perspectiva espacial.

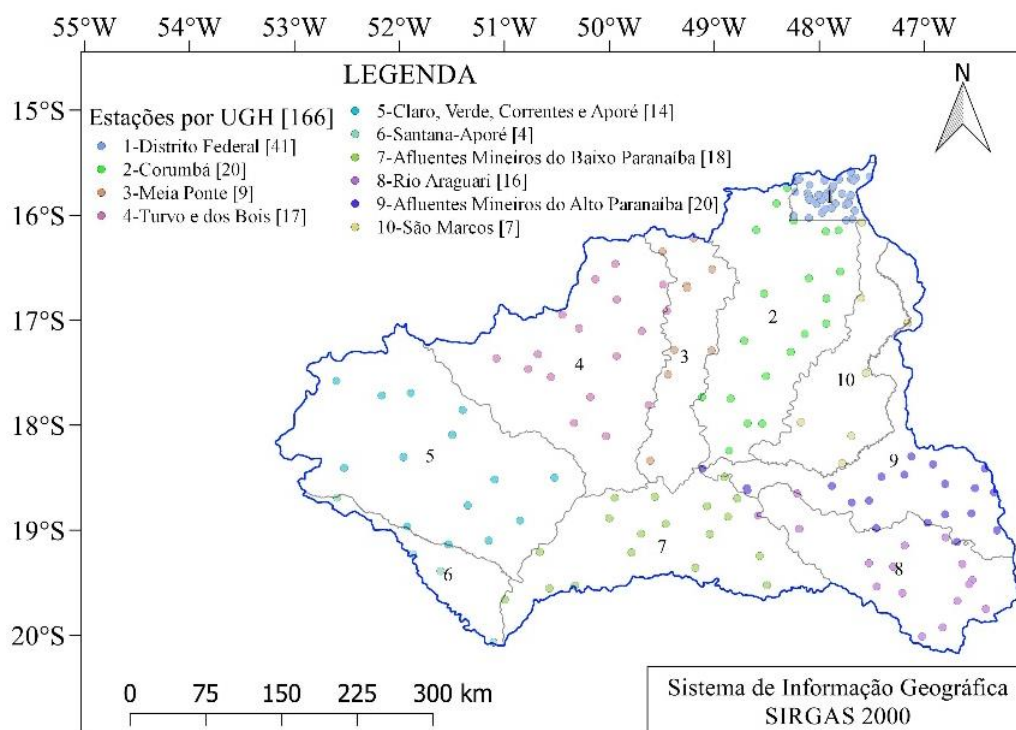


Figura 5.10 – Quantitativo de estações pluviométricas por UGH.

O MAE mensal por UGH (Figura 5.11) apresentou a mesma ordem de grandeza em relação a análise anterior (Figura 5.8). Contudo, a variabilidade dos resultados foi reduzida, mostrando que os erros distribuídos espacialmente se compensaram reduzindo a sua dispersão. O TMPA apresentou a melhor desempenho e o CMORPH a menor variabilidade dentre os produtos.

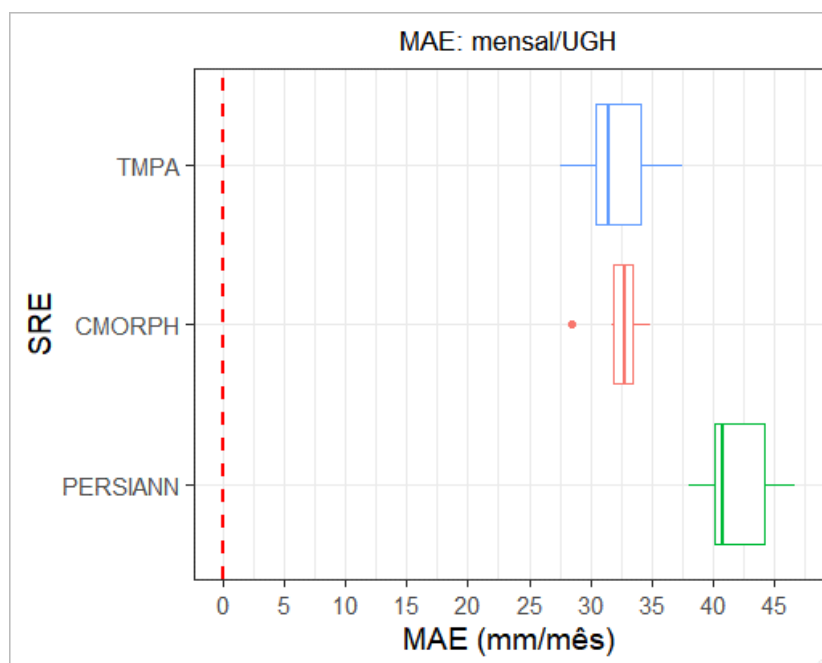


Figura 5.11 – Box plots da métrica MAE mensal por UGH para todos os SRE.

Os mapas da Figura 5.12 apresentam o KGE' de cada produto de satélite avaliado por UGH.

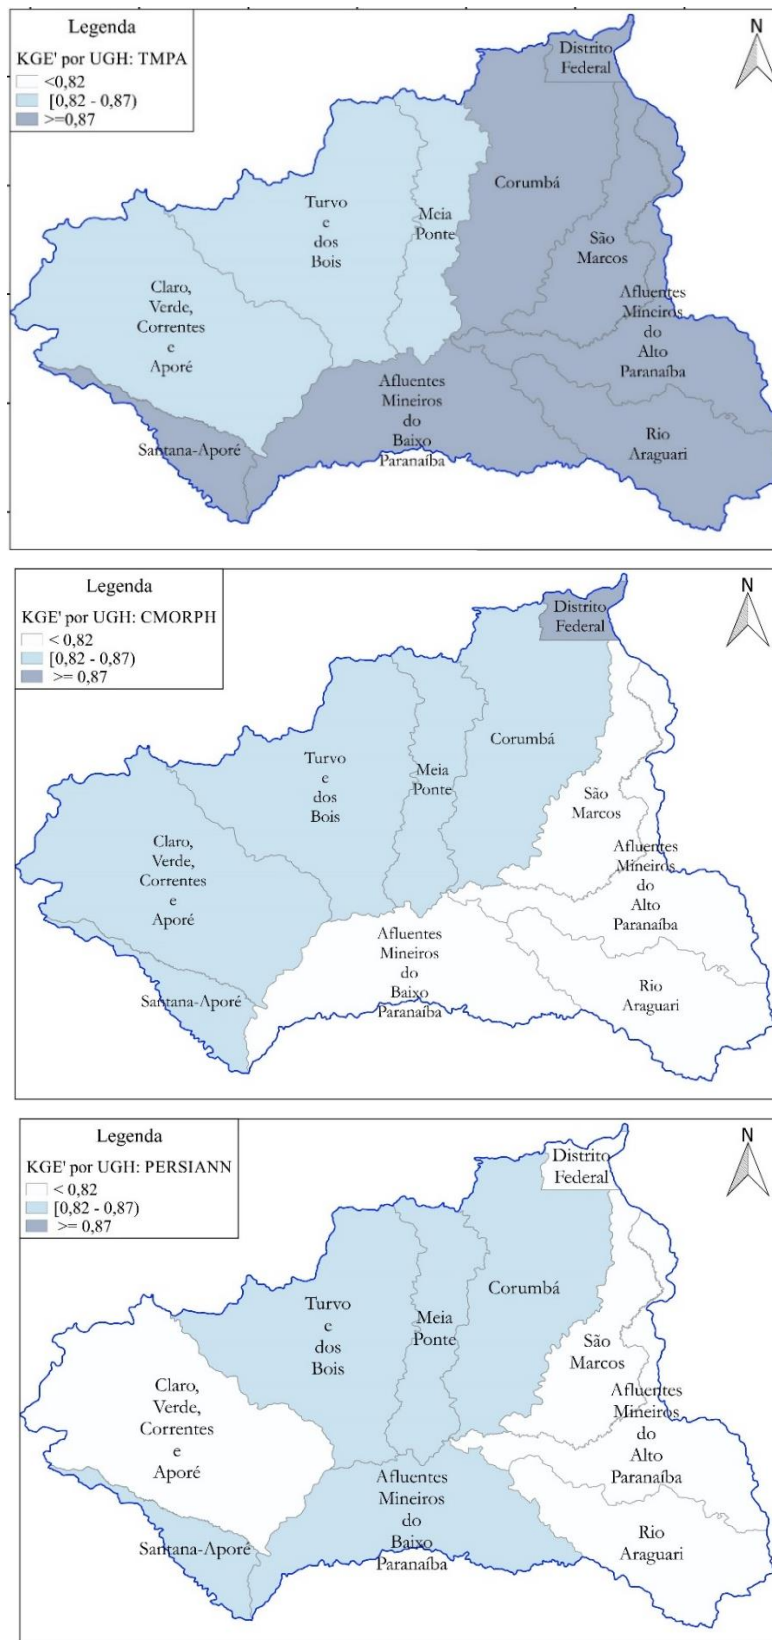


Figura 5.12 – Mapas da métrica KGE' mensal por UGH para todos os produtos.

O produto TMPA, de forma geral, apresentou um desempenho superior aos demais ($KGE' > 0,82$). Seus melhores resultados ocorreram na região leste e sul da bacia. Comparativamente, o melhor desempenho do CMORPH ocorreu nas UGH localizadas ao norte e oeste da bacia do rio Paranaíba, enquanto o PERSIANN foi na região central.

Não é aparente que um determinado SRE apresente um melhor valor de KGE' em uma UGH específica. Nota-se, entretanto, que todos os produtos apresentaram certa regularidade nas UGH Turvo e dos Bois e Meia Ponte. Destaca-se uma peculiaridade na UGH-Distrito Federal: enquanto TMPA e CMORPH obtiveram o melhor valor nessa região ($KGE' > 0,87$), o PERSIANN obteve o pior ($KGE' < 0,82$).

As componentes da KGE' apresentaram valores similares aos da análise mensal por estação (APÊNDICES). Entretanto, nota-se que todas as métricas (MAE, KGE' e componentes) reduziram a variabilidade dos resultados, realçando que, ao agregar a escala espacial da análise, há uma suavização de extremos pontuais. Assim, os valores da métrica aproximam-se da média.

Por fim, os resultados foram analisados sazonalmente para toda bacia, isto é, mês a mês e independente da UGH. A Figura 5.13 apresenta os *box plots* da métrica MAE para todos os produtos. Uma figura análoga a essa está descrita nos APÊNDICES, entretanto nela computou-se as métricas considerando as séries mensais das estações.

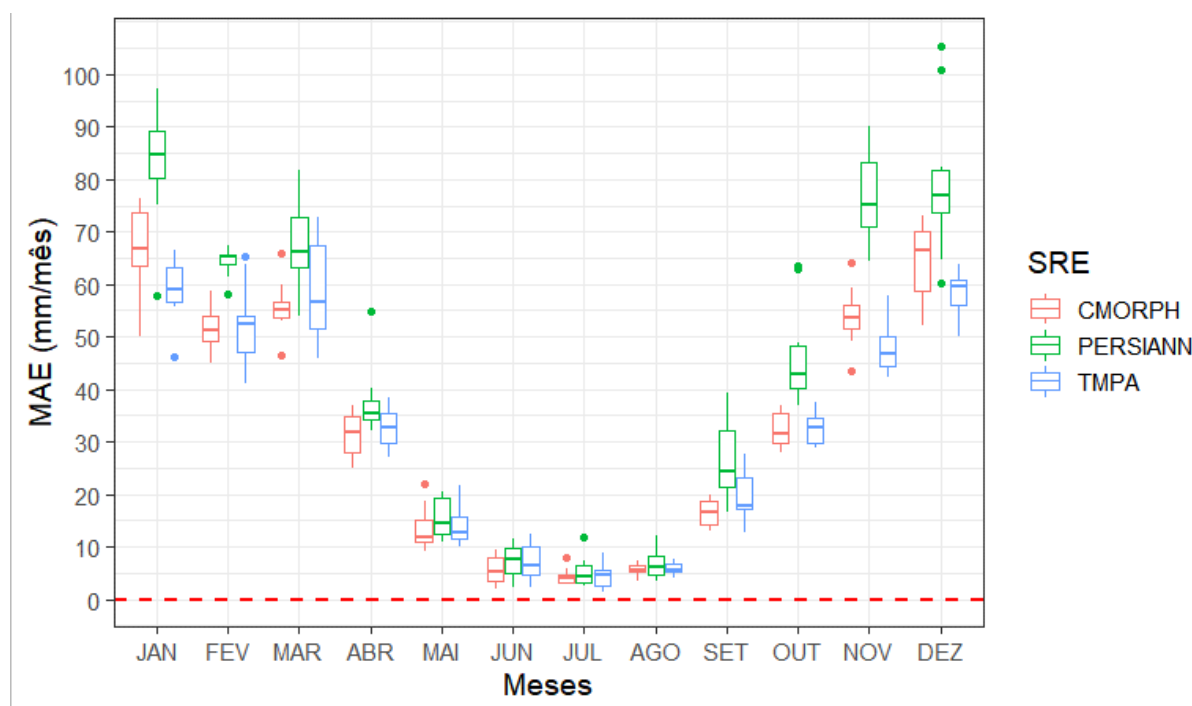


Figura 5.13 – *Box plots* da métrica MAE mensal por UGH por mês para todos os SRE.

Evidencia-se, nitidamente, uma sazonalidade nas diferenças entre estimativas de satélite e registros de pluviômetros. No trimestre mais seco (junho a agosto) todos os produtos apresentaram as menores diferenças absolutas ($MAE < 15$ mm/mês). Em contraposição, no trimestre mais úmido (novembro a janeiro) as maiores diferenças foram observadas ($MAE > 40$ mm/mês). Essa sazonalidade está em acordo com os resultados prévios: as estimativas de satélite são hábeis em identificar a não ocorrência de chuvas, no entanto, a intensidade em dias chuvosos apresenta diferenças notáveis, sobretudo na escala diária. O TMPA e CMORPH apresentam os melhores resultados em meses alternados. O PERSIANN sistematicamente apresentou performance inferior aos outros produtos

5.1.3 Desempenho na escala anual

A série de dados anuais foi concebida por meio da agregação dos dados mensais de todas as estações. Devido aos critérios da análise preliminar de dados (Tabela 4.3), houve uma redução de 166 estações na escala mensal para 143 estações na escala anual. Os dados anuais das estações foram analisados para bacia, isso é, independente da UGH. Isso é necessário, pois o número de dados se reduz expressivamente, impossibilitando uma análise espacial e muito menos local.

A Tabela 5.8 apresenta as estatísticas descritivas de toda a série de dados na escala anual. Todas as estatísticas se aparentam divergentes entre as séries. Exceto pelas medianas e médias entre CMORPH e PERSIANN, e os coeficientes de variação entre os pluviômetros e o CMORPH.

Tabela 5.8 – Estatísticas descritivas para a série de dados anuais por estação pluviométrica para todos os medidores.

Estatísticas descritivas	Pluviômetros			
	ANA	TMPA 3B42	CMORPH	PERSIANN
Mínimo (mm/ano)	861	592	716	580
Máximo (mm/ano)	2.223	1.968	1.843	2.452
Mediana (mm/ano)	1.401	1.507	1.283	1.282
Média (mm/ano)	1.417	1.510	1.279	1.292
Desvio padrão (mm/ano)	214	172	195	289
Coeficiente de variação	0,15	0,11	0,15	0,22

A Tabela 5.9 apresenta as medianas das métricas MAE, KGE' e suas componentes na escala anual para todos os produtos. O TMPA apresentou performance ligeiramente superior aos demais produtos. Em contraponto às expectativas, a escala anual apresentou resultados inferiores à mensal e, inclusive em alguns casos, piores que a diária quando analisadas estações

específicas. Enquanto as componentes β e γ são relativamente próximas ao melhor valor calculado (semelhantes as faixas de valores observadas na escala mensal), a correlação linear foi reduzida expressivamente.

Tabela 5.9 – Medianas das métricas MAE, KGE' e suas componentes na escala anual para todos os SRE.

Produtos de satélite	MAE (mm/ano)	KGE'	Componentes KGE'		
			r	β	γ
TMPA	165	0,38	0,49	1,07	0,72
CMORPH	208	0,37	0,39	0,91	0,94
PERSIANN	224	0,28	0,35	0,93	1,18

Resultados semelhantes aos encontrados foram reportados por Zambrano-Bigiarini *et al.* (2017). Os autores inferiram que houve uma amplificação do viés sistemático dos dados diários quando agregados na escala anual. Contrariamente, resultados como os de Reis, Rennó e Lopes (2017), mostraram que os SRE avaliados desempenharam melhor na escala anual do que na diária. Os *box plots* de todas as métricas por UGH na escala anual estão na seção APÊNDICES.

5.2 Avaliação das técnicas de correção de viés

Os resultados apresentados nessa seção correspondem à aplicação da regressão linear e mapeamento de quantis em duas abordagens: na escala diária por estação e na escala mensal por Unidades de Gestão Hídrica. Reiterando, os modelos foram ajustados utilizando-se 50% dos dados disponíveis (calibração), e avaliados com os 50% dos dados restantes (validação). A hipótese é que as fontes de erros se manterão inalteradas entre os períodos avaliados. Nesse caso, o grau de correção deve ser similar (independentemente do período). Entretanto, preteriu-se essa análise em detrimento da avaliação da eficiência das técnicas.

5.2.1 Avaliação da correção de viés na escala diária por estação

A Tabela 5.10 mostra as medianas das métricas MAE e KGE' antes e após a regressão linear e o mapeamento de quantis para os dados no período de validação. Ambas as técnicas não reduzem os resultados da métrica MAE (independente do SRE). De fato, a diferença entre os SRE e os pluviômetros, em média, apresentou um leve aumento, inferior no mapeamento de quantis, que seguiu a mesma tendência.

Em relação ao KGE', enquanto a regressão linear reduziu os valores para os dados corrigidos de todos os SRE, o mapeamento de quantis os manteve constante para os produtos TMPA e CMORPH. Os *box plots* dessas métricas estão na seção APÊNDICES.


Tabela 5.10 – Medianas das métricas MAE e KGE' antes e após a correção de viés para todos os produtos de satélite.

	Produtos de satélite	MAE	MAE_c*	KGE'	KGE'_c*
Regressão linear	TMPA	3,53	3,83	0,53	0,40
	CMORPH	3,29	3,83	0,52	0,40
	PERSIANN	3,81	4,26	0,35	0,24
Mapeamento de quantis	TMPA	3,53	3,59	0,53	0,54
	CMORPH	3,29	3,45	0,52	0,53
	PERSIANN	3,81	3,99	0,35	0,30

*O índice _c indica a utilização dos dados corrigidos.

O diagrama de dispersão entre os registros dos pluviômetros de duas estações e os dados do satélite CMORPH, no período de validação, estão apresentados na Figura 5.14. A reta pontilhada, em vermelho, possui inclinação de 45° e a azul, contínua, é a de regressão entre os dados.

Os diagramas evidenciam que a dispersão em torno da reta de 45° se manteve inalterada mesmo após a correção de viés por ambas as técnicas. Esses resultados similares mostram que ambas as técnicas não foram capazes de aprimorar a correlação linear entre os medidores, a qual manteve-se constante.



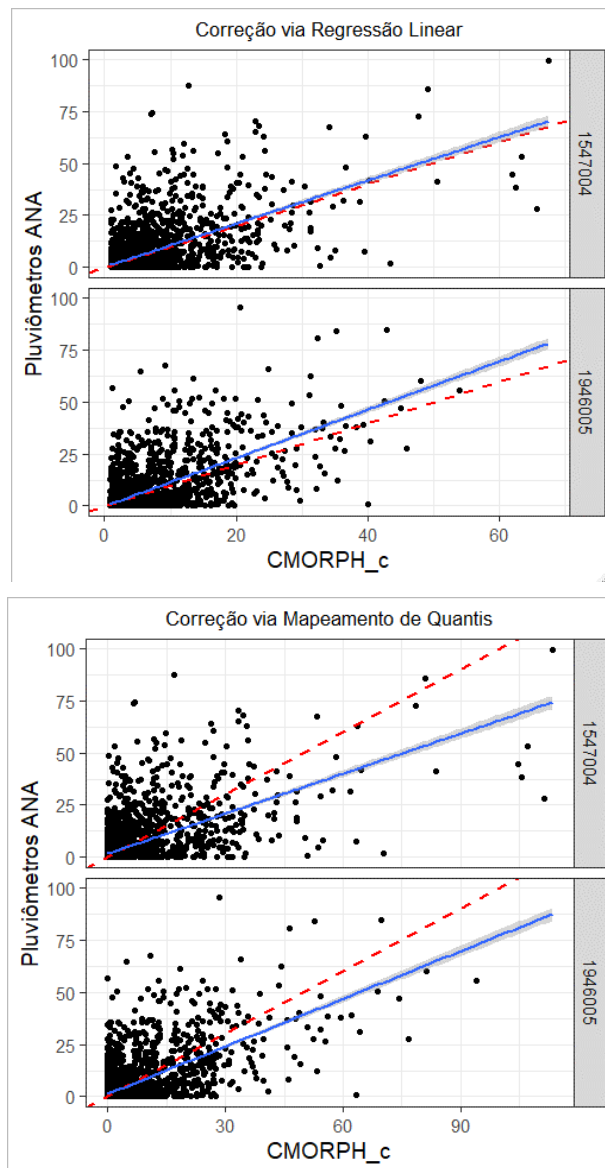


Figura 5.14 – Diagramas de dispersão entre pluviômetro e produto CMORPH antes e após a correção por ambas as técnicas para duas estações.

A modificação na KGE' para os SRE é explicada pelas alterações nas componentes β e γ (Figura 5.15). O parâmetro β foi corrigido por ambas as técnicas, enquanto o parâmetro γ foi corrigido somente pelo mapeamento (a regressão piorou, em termos médios, os resultados obtidos). Para essas componentes, houve uma redução na dispersão dos resultados, notadamente para o produto CMORPH pelo mapeamento de quantis.

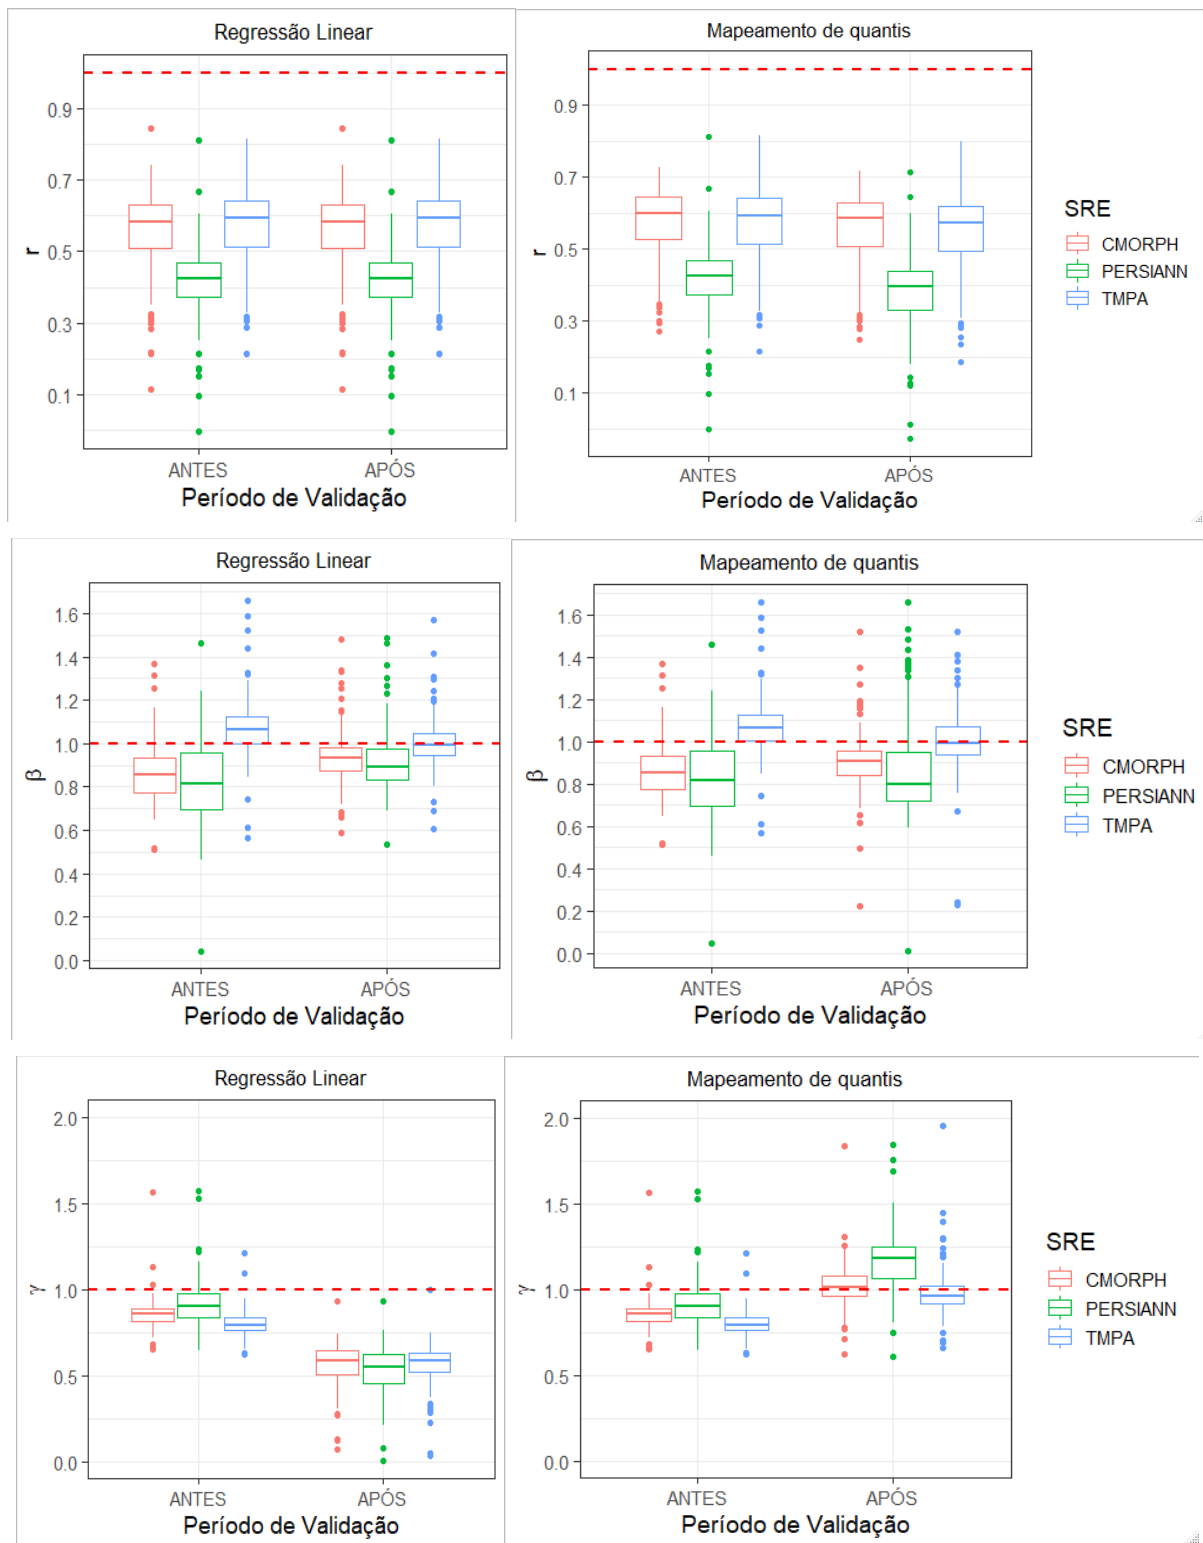


Figura 5.15 – Componentes da métrica KGE' antes e após a correção de viés no período de validação para todos os produtos.

De forma geral, ambas as técnicas corrigiram o viés temporal das diferenças entre os dados dos SRE e dos pluviômetros. Tal correção está exemplificada na Figura 5.16, que mostra a soma

dos dados diários da estação 1946005 e do produto TMPA antes e após a correção no período de validação.




Figura 5.16 – Gráfico de chuva acumulada para a estação 1946005 no período de validação de ambas as técnicas de correção de viés para o produto TMPA.

Os gráficos da Figura 5.17 apresentam mostram as distribuições acumuladas empíricas dos dados da estação 1946005, do produto TMPA antes e após a correção de viés, todos no período de validação. Nota-se que a regressão afastou a distribuição dos dados corrigidos da distribuição dos dados observados. Contudo, o mapeamento propiciou o contrário.

Essas características de ambas as técnicas foram comumente reportadas na literatura (LAFON *et al.*, 2013; POTTER *et al.*, 2019; TSCHÖKE *et al.*, 2017). Enquanto a regressão é capaz de aproximar somente o primeiro momento entre as distribuições dos dados, o mapeamento aproxima também momentos de ordem superior (desvio padrão, assimetria e curtose). Isso faz com que ele se sobressaia à regressão em igualar as distribuições entre os dados. Portanto, concorda-se com os estudos citados, de que o mapeamento de quantis é uma função de transformação mais eficiente do que a regressão.




Figura 5.17 – Funções empíricas de distribuição acumulada da estação 1946005 antes e após a correção de viés para o produto TMPA.

Reiterando, ambas as técnicas possibilitaram uma aproximação de algum momento entre as distribuições dos SRE das distribuições observadas. Em ambos os casos, considerando que as distribuições das chuvas possam vir a ser estacionárias, as técnicas serão capazes de reduzir, em parte, o viés sistemático temporal de dados futuros.

5.2.2 Avaliação da correção de viés na escala mensal por UGH

Os dados mensais utilizados para ambas as técnicas compreendem as séries das estações pertencentes a sua respectiva UGH, conforme Figura 5.10. Com relação a ambas as técnicas, a Tabela 5.11 mostra as métricas MAE e KGE' antes e após a correção de viés para todos os produtos no período de validação.

Tabela 5.11 - Métricas MAE e KGE' antes e após a correção de viés para todos os produtos de satélite.

	Produtos de satélite	MAE	MAE_c	KGE'	KGE'_c
Regressão linear	TMPA	32	31	0,87	0,88
	CMORPH	33	33	0,85	0,87
	PERSIANN	42	44	0,82	0,78
Mapeamento de quantis	TMPA	32	32	0,87	0,90
	CMORPH	33	34	0,85	0,88
	PERSIANN	42	43	0,82	0,84

Os resultados se mostram bastantes similares antes e após a correção. Em outras palavras, os satélites não mostram uma tendência comum de melhorar ou piorar determinada métrica. Os *box plots* de ambas as métricas estão na seção APÊNDICES.

Não houve aprimoramento na correlação linear (r) mensal com os dados em superfície para nenhum produto (*box plot* na seção APÊNDICES). As componentes da KGE' que apresentaram modificações aparentes foram a β e γ (Figura 5.18). Assim como na escala diária, a componente β foi aprimorada por ambas as técnicas, e sua dispersão foi severamente reduzida, em especial, pelo mapeamento de quantis.

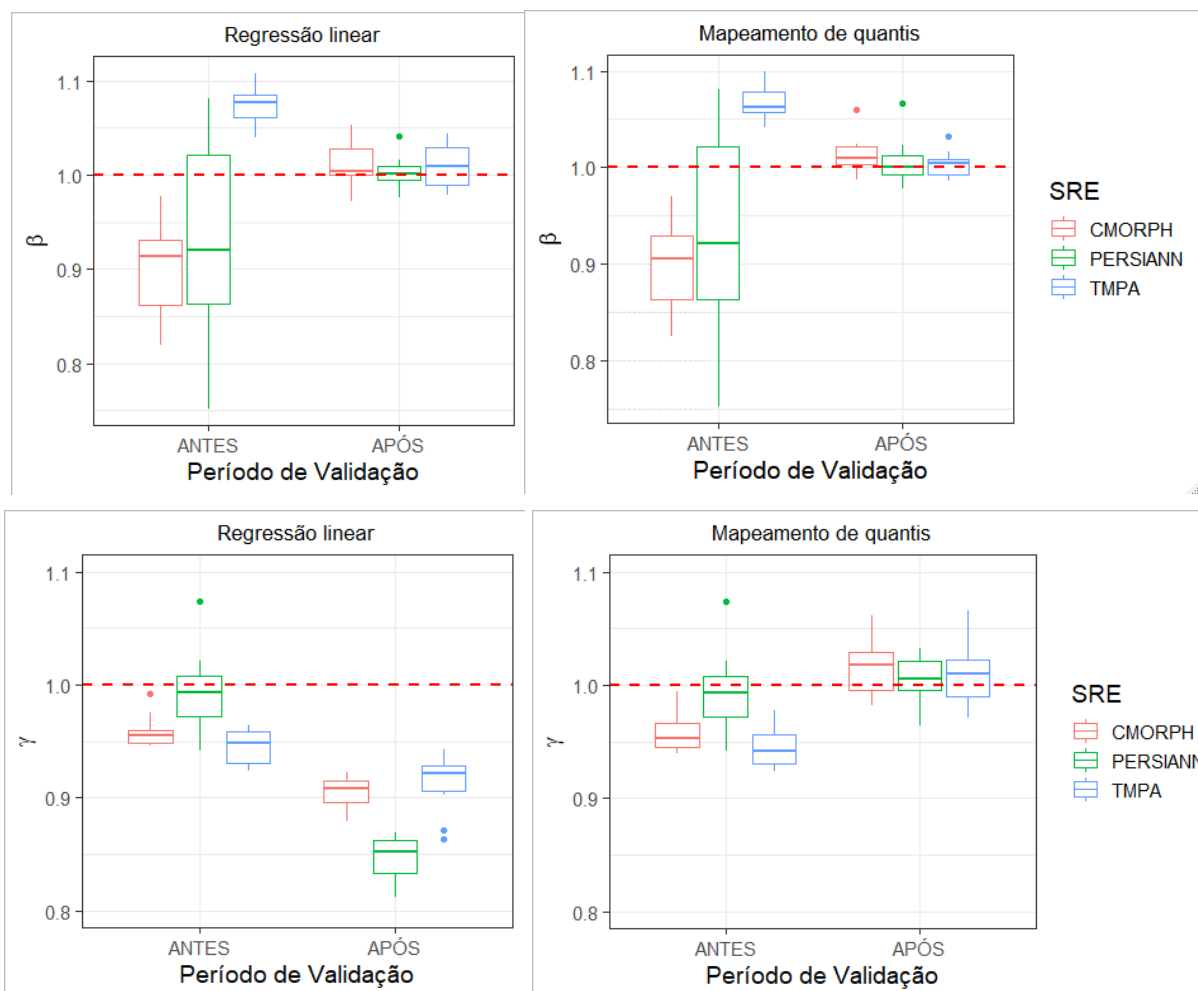


Figura 5.18 – Componentes β e γ antes a após a correção de viés na escala mensal para todos os produtos.

A componente γ foi aprimorada somente pelo mapeamento de quantis. Entretanto, enquanto a dispersão do produto PERSIANN foi reduzida, aquelas dos produtos TMPA e CMORPH aumentaram.

A Figura 5.19 mostra a chuva mensal agregada da UGH Corumbá e do produto CMORPH antes e após a correção no período de validação. Nota-se que o total acumulado do CMORPH corrigido (CMORPH_c) aproxima-se dos registrados nos pluviômetros. Isso evidencia que,

assim como na escala diária, ambas as técnicas foram capazes de corrigir o viés temporal entre os dados de satélite e dos pluviômetros.




Figura 5.19 – Gráfico de chuva acumulada para a UGH-Corumbá no período de validação de ambas as técnicas de correção de viés para o produto CMORPH.

A Figura 5.20 apresenta as distribuições acumuladas empíricas dos pluviômetros da UGH Distrito Federal e do produto CMORPH antes e após a correção de viés por ambas as técnicas. Assim como observado na escala diária, o mapeamento de quantis equalizou de forma mais eficaz as distribuições entre os dados corrigidos e os dados dos pluviômetros.




Figura 5.20 – Funções empíricas de distribuição acumulada da UGH-Distrito Federal antes e após a correção de viés para o produto CMORPH.

De forma geral, os melhores resultados para a correção de viés foram obtidos para os produtos TMPA e CMORPH, o que era esperado pois os mesmos, na maioria das análises, apresentaram desempenho superior ao produto PERSIANN (Seção 5.1).

Ambas as técnicas se mostraram adaptáveis a alteração da escala temporal (diária e mensal) e espacial (estação e UGH). As mesmas foram capazes de aprimorar o primeiro momento das distribuições dos dados de satélite. Conseqüentemente, quando se acumula a chuva para uma determinada estação (Figura 5.16) ou UGH (Figura 5.19), evidencia-se que os acumulados corrigidos se aproximam dos acumulados observados. Entretanto, o erro se manteve com a mesma magnitude em todas as escalas, sugerindo que sua estrutura seja complexa, provavelmente necessitando de distribuições de probabilidade com mais de três parâmetros para o seu ajuste.

Somente o mapeamento por distribuição não paramétrica foi capaz de aproximar o segundo momento entre as distribuições de satélite e a distribuições dos pluviômetros. Isso demonstra uma maior robustez dessa técnica perante a regressão linear. No entanto, por ser uma abordagem não paramétrica, a mesmo apresenta dificuldades na extrapolação de seus resultados na cauda superior em situações que para uma dada estação, as precipitações máximas de ambos os medidores (pluviômetros e satélites) diferem significativamente. Ademais, é comum que essa técnica necessite de um modelo adicional para interpolação de resultados entre os já tabelados durante o período de calibração. Isso pode aumentar as incertezas desses resultados.

6. CONCLUSÕES E RECOMENDAÇÕES

O presente estudo se propôs a caracterizar as diferenças entre três estimativas de precipitação por satélite (TMPA, CMORPH_v1.0-CRT e PERSIANN) e as obtidas por pluviômetros sobre a bacia do rio Paranaíba, localizada no centro-oeste brasileiro. Para isso, avaliou-se o desempenho desses produtos em diferentes escalas temporais (diária, mensal e anual) entre os anos 2000 a 2017.

Essa verificação utilizou métricas de ocorrência de chuva (POD, FAR e fBIAS) e métricas de acurácia (MAE e KGE'). As primeiras examinaram a capacidade dos produtos em identificar corretamente diferentes intensidades de precipitação. Já as outras foram utilizadas com o intuito de identificar possíveis fontes de erros sistemáticos desses produtos.

Sumariamente, os resultados mostraram que o produto TMPA obteve desempenho superior em todas as escalas temporais. Pontua-se que, devido às dimensões do estudo, a identificação do desse desempenho foi baseada nas medianas dos resultados. Não se pode afirmar que o TMPA foi superior em todas as análises realizadas.

Especificamente, com relação aos índices categóricos, todos os produtos mostraram boa capacidade em identificar a ocorrência ou não de chuvas. No entanto, durante os dias chuvosos, esses apresentaram baixa habilidade em fornecer uma classificação precisa das diferentes intensidades de precipitação quando comparados aos pluviômetros.

Na escala diária, com relação a métrica MAE, todos produtos demonstram erros quando comparados aos pluviômetros. Os quais se mostraram elevados na abordagem por classes de eventos. Contudo, devido aos produtos demonstrarem uma alta probabilidade de detecção (POD $\sim 0,9$) e um erro baixo (MAE ~ 1 mm/dia) para classe “sem chuva” (< 1 mm/dia), recomenda-se a utilização desses para verificação e preenchimento de falhas dos registros históricos das estações pluviométricas.

A métrica KGE' forneceu uma avaliação geral do desempenho dos SRE. Além disso, as suas componentes nos permitiram entender se os erros desses advém da dinâmica temporal (medida pelo r), do volume de chuva (medida pelo β) ou da variabilidade das intensidades (medida pelo γ). Observou-se que apesar de sempre positivas, as correlações lineares são as componentes que obtiveram resultados inferiores perante as demais, independente do produto. Isso realça a

dificuldade dos SRE em identificar as precipitações em concordância temporal com os pluviômetros. Portanto, recomenda-se que, os produtores de estimativas de precipitação por satélite devem focar em correções nos seus algoritmos que aprimorem a correlação linear com os dados de superfície.

Alguns estudos demonstraram que a performance de alguns SRE foi influenciada pela topografia local. Devido a isso, foi realizada uma verificação simplificada dessa hipótese sobre a bacia do rio Paranaíba. Mas os resultados não mostraram, aparentemente, algum efeito desse tipo sobre o desempenho dos produtos analisados. No entanto, para um resultado mais conclusivo, esse tópico carece de mais fundamentação e análises específicas.

Outra questão que remanesce é, se o procedimento de interpolação espacial adotado (BWI) antes da validação, aprimorou ou não o desempenho dos mesmos, ou se foi favorável ou não para algum produto em específico. Por conseguinte, recomenda-se que se verifique o desempenho antes e após qualquer processo de interpolação espacial, independente da fonte interpolada (pluviômetros ou SRE). Isso é extremamente relevante visto que, alguns estudos, demonstraram que esse procedimento pode afetar os resultados da seleção do produto mais representativo dos padrões espaço-temporais da precipitação de uma região.

Persistentemente, o produto PERSIANN obteve desempenho inferior na maioria das análises. Contudo, esse resultado era esperado principalmente por dois motivos cardeais: é o único produto que utiliza como fonte primária sensores do tipo infravermelho-visível; e que não utiliza informações de precipitação em solo para algum tipo de calibração/correção. Entretanto, esse SRE possui a menor latência de produção dentre os analisados, o que o torna elegível para a utilização de forma imediata. Portanto, recomenda-se, sempre que possível, validar produtos de baixa latência, visto que os usuários tendem a utilizar esses dados para aplicações em casos de urgência.

Na escala mensal, todos os produtos obtiveram desempenhos superiores à escala diária. Os erros temporais de subestimativa e superestimativa nas escalas diárias foram compensados quando agregados nessa escala. Já os erros espaciais foram suavizados quando agrupados em maiores escalas (UGHs e Bacia do Paranaíba). Em outras palavras, quanto maior o período de tempo de acumulação e quanto maior a escala espacial, os estimadores de chuva estão menos sujeitos à grande variabilidade espaço-temporal desse fenômeno.

Os produtos obtiveram resultados inferiores na escala anual quando comparados com escala mensal, e em alguns casos até com a escala diária. A correlação linear da KGE' foi a que realçou essa disparidade. Esse resultado foi semelhante ao encontrado em alguns estudos. Entretanto, outros trabalhos demonstraram o contrário. Ainda remanesce desconhecido o motivo pelo qual isso aconteceu.

Devido os erros identificados para todos os produtos em todas as escalas temporais, aplicou-se duas técnicas para correção de viés nas escalas diária e mensal. Ambas as técnicas (regressão linear e mapeamento de quantis por distribuições não paramétricas) foram capazes de aproximar as médias (primeiro momento) entre as distribuições dos dados dos SRE e das distribuições dos dados dos pluviômetros. Conforme esperado, o mapeamento aproximou outros momentos dessas distribuições. Apesar do erro se manter praticamente constante, ambas corrigiram o viés temporal dos produtos de satélite.

Como o desempenho dos produtos apresentou características sazonais – todos apresentaram melhor performance nos meses mais secos do que nos meses mais úmidos – recomenda-se que as técnicas para correção de viés sejam aplicadas agrupando dados de forma sazonal. Possivelmente, essa segmentação otimizará a eficácia das técnicas, pois o viés será tratado de acordo com a sua especificidade, o que pode aprimorar os resultados. Ademais, se o erro for estacionário, indica-se sempre aplicar uma técnica para correção dos dados de satélite, para que se tenha informações (dados) mais adequadas para fins hidrológicos.

Parece razoável que o elevado erro entre pluviômetros e satélites demonstre uma estrutura de incerteza complexa. Entretanto, alguns desses podem estar associados a operação da rede pluviométrica pela ANA, causa pela qual o Instituto de Pesquisas Espaciais (INPE) utiliza sistematicamente dados de estações gerenciadas pelos Instituto Nacional de Meteorologia (INMET) em estudos desse escopo, os quais são considerados de maior confiabilidade.

Não se indica a utilização dos produtos de satélite analisados em aplicações hidrológicas de forma direta sobre a bacia do rio Paranaíba. Entretanto, recomenda-se a utilização desses de forma complementar as informações dos pluviômetros, particularmente quando se necessita de informações dos padrões espaciais de precipitação.

Os resultados deste estudo podem ser utilizados somente para fins de comparação e não podem ser extrapolados para outras bacias. Conclui-se que apesar da evolução contínua nos algoritmos

dos produtos de satélite, os mesmos apresentam erros quando comparados a dados considerados de maior confiabilidade. Uma validação regional ainda se torna necessária, a fim de ter um diagnóstico específico da performance dessas em cada localidade ao longo da bacia do Paranaíba.

Finalmente, sugere-se que para um aprofundamento da caracterização das diferenças entre estimadores de chuva, utilize-se de modelos de erros. Esses são capazes de caracterizar a estrutura multidimensional (temporal e espacial) das diferenças entre dados de satélite e dados ditos de referência (independente da fonte: radar ou pluviômetros). Com isso é possível realizar simulações equiprováveis desse erro. Isso oferece uma gama de possibilidades para a modelagem hidrológica, objetivando realizar inferências fidedignas dos padrões espaço-temporais das precipitações de uma determinada região.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ABERA, W.; BROCCA, L.; RIGON, R. Comparative evaluation of different satellite rainfall estimation products and bias correction in the Upper Blue Nile (UBN) basin. **Atmospheric Research**, v. 178–179, p. 471–483, 2016.

ACHARYA, S. C. *et al.* An evaluation of daily precipitation from atmospheric reanalyses over Australia. **Hydrology and Earth System Sciences Discussions**, p. 1–32, 19 fev. 2019.

AGÊNCIA NACIONAL DAS ÁGUAS. **Cartilha do observador: pluviometria**. Brasília, 2014. Disponível em: <http://arquivos.ana.gov.br/institucional/sge/CEDOC/Catalogo/2014/CartilhaDoObservador-Pluviometria.pdf>. Acesso em: 15 jan. 2019.

AGÊNCIA NACIONAL DAS ÁGUAS. Superintendência de Gestão da Rede Hidrometeorológica. **Orientações para consistência de dados pluviométricos**. Brasília: ANA, 2012. Disponível em: <http://arquivos.ana.gov.br/infohidrologicas/cadastro/OrientacoesParaConsistenciaDadosPluviometricos-VersaoJul12.pdf>. Acesso em: 18 abr. 2018.

AGÊNCIA NACIONAL DAS ÁGUAS. **Plano de recursos hídricos e do enquadramento dos corpos hídricos superficiais da bacia hidrográfica do rio Paranaíba**. Brasília: ANA, 2015.

AHRENS, C. Donald; HENSON, Robert. **Essentials of meteorology: an invitation to the atmosphere**. 8ª ed. Boston: Brooks Cole, 2017.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Atlas de energia elétrica do Brasil**. 3ª. ed. Brasília: [s. n.], 2008. 1 atlas. E-book (236 p.).

ARKIN, P. A.; JOYCE, R.; JANOWIAK, J. E. The estimation of global monthly mean rainfall using infrared satellite data: The GOES precipitation index (GPI). **Remote Sensing Reviews**, v. 11, n. 1–4, p. 107–124, out. 1994.

ASHOURI, H. *et al.* PERSIANN-CDR: Daily Precipitation Climate Data Record from Multisatellite Observations for Hydrological and Climate Studies. **Bulletin of the American Meteorological Society**, v. 96, n. 1, p. 69–83, jan. 2015.

BA, M. B.; GRUBER, A. GOES Multispectral Rainfall Algorithm (GMSRA). **Journal of Applied Meteorology**, v. 40, n. 8, p. 1500–1514, 2001.

BAEZ-VILLANUEVA, O. M. *et al.* Temporal and spatial evaluation of satellite rainfall estimates over different regions in Latin-America. **Atmospheric Research**, v. 213, p. 34–50, nov. 2018.

BAI, P.; LIU, X. Evaluation of Five Satellite-Based Precipitation Products in Two Gauge-Scarce Basins on the Tibetan Plateau. **Remote Sensing**, v. 10, n. 8, p. 1316, 2018.

BARBOSA, H. A.; LAKSHMI KUMAR, T. V. Influence of rainfall variability on the vegetation dynamics over Northeastern Brazil. **Journal of Arid Environments**, v. 124, p. 377–387, jan. 2016.

BEAUFORT, A.; GIBIER, F.; PALANY, P. Assessment and correction of three satellite rainfall estimate products for improving flood prevention in French Guiana. **International Journal of Remote Sensing**, v. 40, n. 1, p. 171–196, 2 jan. 2019.

BECK, H. E. *et al.* Daily evaluation of 26 precipitation datasets using Stage-IV gauge-radar data for the CONUS. **Hydrology and Earth System Sciences**, v. 23, n. 1, p. 207–224, 16 jan. 2019.

BECK, H. E. *et al.* Global-scale evaluation of 22 precipitation datasets using gauge observations and hydrological modeling. **Hydrology and Earth System Sciences**, v. 21, n. 12, p. 6201–6217, 8 dez. 2017.

BECKER, A. *et al.* A description of the global land-surface precipitation data products of the Global Precipitation Climatology Centre with sample applications including centennial (trend) analysis from 1901–present. **Earth System Science Data**, v. 5, n. 1, p. 71–99, 21 fev. 2013.

CABRAL, S. L.; SAKURAGI, J.; SILVEIRA, C. DA S. Incertezas e erros na estimativa de vazões usando modelagem hidrológica e precipitação por RADAR. **Revista Ambiente e Água**, v. 12, n. 1, p. 57–70, 2016.

CAI, J. SEN *et al.* Importance of variability in initial soil moisture and rainfalls on slope stability. **Journal of Hydrology**, v. 571, p. 265–278, 2019.

CAPDEROU, Michel. **Handbook of satellite orbits: from Kepler to GPS**. 1ª ed. New York: Springer International Publishing, 2014. 922 p.

CARACCIOLO, D. *et al.* Performances of GPM satellite precipitation over the two major Mediterranean islands CLIMB -Climate Induces Changes on the Hydrology of Mediterranean Basins View project CLIMB FP7 View project. **Atmospheric Research**, v. 213, n. June, p. 309–322, 2018.

CHEN, S.; GUO, J. Spatial interpolation techniques: their applications in regionalizing climate-change series and associated accuracy evaluation in Northeast China. **Geomatics, Natural Hazards and Risk**, v. 8, n. 2, p. 689–705, 2017.

CHEN, Y. *et al.* Evaluation of TRMM 3B42 precipitation estimates of tropical cyclone rainfall using PACRAIN data. **Journal of Geophysical Research Atmospheres**, v. 118, n. 5, p. 2184–2196, 2013.

COLLISCHONN, Walter; DORNELLES, Fernando (ed.). **Hidrologia para engenharia e ciências ambientais**. 2ª ed. rev. e amp. Porto Alegre: ABRH, 2015.

DARAND, M.; AMANOLLAHI, J.; ZANDKARIMI, S. Evaluation of the performance of TRMM Multi-satellite Precipitation Analysis (TMPA) estimation over Iran. **Atmospheric Research**, v. 190, p. 121–127, jul. 2017.

DAWSON, C. W.; ABRAHART, R. J.; SEE, L. M. HydroTest: A web-based toolbox of evaluation metrics for the standardised assessment of hydrological forecasts. **Environmental Modelling & Software**, v. 22, n. 7, p. 1034–1052, jul. 2007.

DAWSON, C. W.; ABRAHART, R. J.; SEE, L. M. HydroTest: Further development of a web resource for the standardised assessment of hydrological models. **Environmental Modelling and Software**, v. 25, n. 11, p. 1481–1482, 2010.

DINKU, T. *et al.* Validation of the CHIRPS satellite rainfall estimates over eastern Africa. **Quarterly Journal of the Royal Meteorological Society**, v. 144, n. S1, p. 292–312, 6 nov. 2018.

DOS REIS, J. B. C.; RENNÓ, C. D.; LOPES, E. S. S. Validation of Satellite Rainfall Products over a Mountainous Watershed in a Humid Subtropical Climate Region of Brazil. **Remote Sensing**, v. 9, n. 1240, p. 01–18, 1 dez. 2017.

EBERT, E. E. METHODS FOR VERIFYING SATELLITE PRECIPITATION ESTIMATES. In: **Measuring Precipitation From Space**. [s.l: s.n.]. p. 345–356.

EBRAHIMI, S. *et al.* Effects of temporal scales and space mismatches on the TRMM 3B42 v7 precipitation product in a remote mountainous area. **Hydrological Processes**, v. 31, n. 24, p. 4315–4327, 2017.

EMMANUEL, I. *et al.* Influence of rainfall spatial variability on rainfall-runoff modelling: Benefit of a simulation approach? **Journal of Hydrology**, v. 531, p. 337–348, 2015.

FARIDZAD, M. *et al.* Rainfall frequency analysis for ungauged regions using remotely sensed precipitation information. **Journal of Hydrology**, v. 563, p. 123–142, ago. 2018.

FERRARO, R. R. *et al.* Precipitation Characteristics Over Land from the NOAA-15 AMSU Sensor. **Geophysical Research Letters**, v. 27, n. 17, p. 2669–2672, 2000.

FERRARO, R. R. *et al.* Precipitation. In: **Comprehensive Remote Sensing**. [s.l.] Elsevier, 2018. p. 4–24.

FERRARO, R. R. Special sensor microwave imager derived global rainfall estimates for climatological applications. **Journal of Geophysical Research: Atmospheres**, v. 102, n. D14, p. 16715–16735, 1997.

FLEISCHMANN, A. *et al.* Precipitation as a proxy for climate variables: application for hydrological modelling. **Hydrological Sciences Journal**, v. 64, n. 3, p. 361–379, 17 fev. 2019.

FUNK, C. *et al.* The climate hazards infrared precipitation with stations - a new environmental record for monitoring extremes. **Scientific Data**, v. 2, n. 1, p. 1–21, 8 dez. 2015.

GADELHA, A. N. *et al.* Grid box-level evaluation of IMERG over Brazil at various space and time scales. **Atmospheric Research**, v. 218, p. 231–244, abr. 2019.

GADO, T. A.; HSU, K.; SOROOSHIAN, S. Rainfall frequency analysis for ungauged sites using satellite precipitation products. **Journal of Hydrology**, v. 554, p. 646–655, nov. 2017.

GAO, Y. C.; LIU, M. F. Evaluation of high-resolution satellite precipitation products using rain gauge observations over the Tibetan Plateau. **Hydrology and Earth System Sciences**, v. 17, p. 837–849, 2013.

GRIMALDI, S. *et al.* Description and preliminary results of a 100 square meter rain gauge. **Journal of Hydrology**, v. 556, p. 827–834, 2018.

GUDMUNDSSON, L. *et al.* Technical Note: Downscaling RCM precipitation to the station scale using statistical transformations - a comparison of methods. **Hydrology and Earth System Sciences**, v. 16, n. 9, p. 3383–3390, 21 set. 2012.

GUILLOD, B. P. *et al.* A large set of potential past, present and future hydro-meteorological time series for the UK. **Hydrology and Earth System Sciences**, v. 22, n. 1, p. 611–634, 25 jan. 2018.

HONG, Y. *et al.* Remote Sensing Precipitation: Sensors, Retrievals, Validations, and Applications. In: LI, X.; VEREECKEN, H. (Eds.). . **Observation and Measurement of Ecohydrological Processes**. Ecohydrology. Berlin, Heidelberg: Springer Berlin Heidelberg, 2018. p. 1–23.

HONG, Yang; GOURLEY, Jonathan J. **Radar hydrology: principles, models, and applications**. 1ª ed. Flórida: CRC Press, 2015.

HOU, A. Y. *et al.* The global precipitation measurement mission. **Bulletin of the American Meteorological Society**, v. 95, n. 5, p. 701–722, maio 2014.

HSU, K. *et al.* Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks. **Journal of Applied Meteorology**, v. 36, n. 9, p. 1176–1190, set. 1997.

HUANG, W. R.; CHANG, Y. H.; LIU, P. Y. Assessment of IMERG precipitation over Taiwan at multiple timescales. **Atmospheric Research**, v. 214, p. 239–249, dez. 2018.

HUFFMAN, G. J. *et al.* The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-Global, Multiyear, Combined-Sensor Precipitation Estimates at Fine Scales. **Journal of Hydrometeorology**, v. 8, n. 7, p. 38–55, nov. 2007.

HUSSAIN, Y. *et al.* Performance of CMORPH, TMPA, and PERSIANN rainfall datasets over plain, mountainous, and glacial regions of Pakistan. **Theoretical and Applied Climatology**, v. 131, n. 3–4, p. 1119–1132, 12 fev. 2018.

JIMÉNEZ, K. Q.; COLLISCHONN, W. Método de combinação de dados de precipitação estimados por satélite e medidos em pluviômetros para a modelagem hidrológica. **Revista Brasileira de Recursos Hídricos**, v. 20, n. 1, p. 202–217, 2015.

JOYCE, R. J. *et al.* CMORPH: A Method that Produces Global Precipitation Estimates from Passive Microwave and Infrared Data at High Spatial and Temporal Resolution. **Journal of Hydrometeorology**, v. 5, n. 3, p. 487–503, jun. 2004.

KHORRAM, S. *et al.* **Principles of applied remote sensing**. 1ª ed. New York: Springer International Publishing, 2016.

KIDD, C. *et al.* So, How Much of the Earth's Surface Is Covered by Rain Gauges? **Bulletin of the American Meteorological Society**, v. 98, n. 1, p. 69–78, jan. 2017.

KIDD, C. Satellite rainfall climatology: a review. **International Journal of Climatology**, v. 21, n. 9, p. 1041–1066, jul. 2001.

KIDD, C.; HUFFMAN, G. Review: global precipitation measurement. **Meteorological Applications**, v. 18, p. 334–353, 2011.

KIDD, C.; LEVIZZANI, V. Status of satellite precipitation retrievals. **Hydrology and Earth System Sciences**, v. 15, n. 4, p. 1109–1116, 2011.

KIDD, Chris; LEVIZZANI, Vincenzo; LAVIOLA, Sante. Quantitative Precipitation Estimation From Earth Observation Satellites. In: Y. TESTIK, Firat; GEBREMICHAEL, Mekonnen. **Rainfall: State of the Science**. 1^a ed. Washington: American Geophysical Union, 2010.

KIRSCHBAUM, D. B. *et al.* NASA's Remotely Sensed Precipitation: A Reservoir for Applications Users. **Bulletin of the American Meteorological Society**, v. 98, n. 6, p. 1169–1184, jun. 2017.

KUBOTA, T. *et al.* Global Precipitation Map using Satellite-borne Microwave Radiometers by the GSMaP Project: Production and Validation. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 7, p. 2259–2275, jul. 2007.

KULIGOWSKI, R. J. A Self-Calibrating Real-Time GOES Rainfall Algorithm for Short-Term Rainfall Estimates. **Journal of Hydrometeorology**, v. 3, n. 2, p. 112–130, 2002.

KUMMEROW, C. D. *et al.* An observationally generated a priori database for microwave rainfall retrievals. **Journal of Atmospheric and Oceanic Technology**, v. 28, n. 2, p. 113–130, 2011.

KUMMEROW, C. D. *et al.* The evolution of the goddard profiling algorithm to a fully parametric scheme. **Journal of Atmospheric and Oceanic Technology**, v. 32, n. 12, p. 2265–2280, 2015.

KUMMEROW, C. *et al.* The Evolution of the Goddard Profiling Algorithm (GPROF) for Rainfall Estimation from Passive Microwave Sensors. **Journal of Applied Meteorology**, v. 40, p. 1801–1820, 2001.

KUMMEROW, C.; OLSON, W. S.; GIGLIO, L. A simplified scheme for obtaining precipitation and vertical hydrometeor profiles from passive microwave sensors. **IEEE Transactions on Geoscience and Remote Sensing**, v. 34, n. 5, p. 1213–1232, 1996.

LAFON, T. *et al.* Bias correction of daily precipitation simulated by a regional climate model: a comparison of methods. **International Journal of Climatology**, v. 33, n. 6, p. 1367–1381, maio 2013.

LANZA, L. G.; VUERICH, E. The WMO Field Intercomparison of Rain Intensity Gauges. **Atmospheric Research**, v. 94, n. 4, p. 534–543, dez. 2009.

LAVENDER, Samantha; LAVANDER, Andrew. **Practical handbook of remote sensing**. 1^a ed. Flórida: CRC Press, 2015.

LAVERDE-BARAJAS, M. *et al.* Assessing the performance of near real-time rainfall products to represent spatiotemporal characteristics of extreme events: case study of a subtropical catchment in south-eastern Brazil. **International Journal of Remote Sensing**, v. 00, n. 00, p. 1–19, 14 jun. 2018.

LEAL, D. C. RADAR METEOROLÓGICO E SUA IMPORTÂNCIA NA PREVISÃO DE DESASTRES NATURAIS. **XVII Simpósio Brasileiro de Geografia Física Aplicada**, p. 4129–4140, 2017.

LENSKY, I. M.; ROSENFELD, D. Clouds-Aerosols-Precipitation Satellite Analysis Tool (CAPSAT). **Atmospheric Chemistry and Physics**, v. 8, n. 22, p. 6739–6753, 24 nov. 2008.

LEVIZZANI, V. *et al.* Precipitation estimations from geostationary orbit and prospects for METEOSAT Second Generation. **Meteorological Applications**, v. 8, n. 1, p. 23–41, 2001.

LIU, Y. *et al.* Precipitation. *In*: LIANG, Shunlin; LI, Xiaowen; WANG, Jindi (ed.). **Advanced Remote Sensing**. 1^a ed. Cambridge: Academic Press, 2012. cap. 17.

LIU, Z. Comparison of precipitation estimates between Version 7 3-hourly TRMM Multi-Satellite Precipitation Analysis (TMPA) near-real-time and research products. **Atmospheric Research**, v. 153, p. 119–133, fev. 2015.

MA, Y. *et al.* Comprehensive evaluation of Ensemble Multi-Satellite Precipitation Dataset using the Dynamic Bayesian Model Averaging scheme over the Tibetan plateau. **Journal of Hydrology**, v. 556, p. 634–644, jan. 2018.

MAGGIONI, V.; MEYERS, P. C.; ROBINSON, M. D. A Review of Merged High-Resolution Satellite Precipitation Product Accuracy during the Tropical Rainfall Measuring Mission (TRMM) Era. **Journal of Hydrometeorology**, v. 17, n. 4, p. 1101–1117, abr. 2016.

MARAUN, D. Bias Correcting Climate Change Simulations - a Critical Review. **Current Climate Change Reports**, v. 2, n. 4, p. 211–220, 2016.

MARENGO, J. A. Interannual variability of surface climate in the Amazon basin. **International Journal of Climatology**, v. 12, n. 8, p. 853–863, 1992.

MARENGO, J. A. Interdecadal variability and trends of rainfall across the Amazon basin. **Theor. Appl. Climatol**, v. 78, p. 79–96, 2004.

MARRA, F. *et al.* Precipitation frequency analysis from remotely sensed datasets: A focused review. **Journal of Hydrology**, v. 574, n. April, p. 699–705, jul. 2019.

MICHAELIDES, S. *et al.* Precipitation: Measurement, remote sensing, climatology and modeling. **Atmospheric Research**, v. 94, n. 4, p. 512–533, dez. 2009.

MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO. **Modelagem climática e vulnerabilidades setoriais à mudança do clima no Brasil**. Brasília: MCTI - Ministério da Ciência, Tecnologia e Inovação, 2016. Disponível em: <http://www.terrabrasilis.org.br/ecotecadigital/index.php/estantes/diversos/3617-modelagem-climatica-e-vulnerabilidades-setoriais-a-mudanca-do-clima-no-brasil>. Acesso em: 15 jan. 2019.

NAGUETTINI, Mauro; PINTO, Éber José de Andrade. **Hidrologia estatística**. Belo Horizonte: CPRM, 2007.

NGUYEN, P. *et al.* The PERSIANN Family of Global Satellite Precipitation Data: A Review and Evaluation of Products. **Hydrology and Earth System Sciences Discussions**, v. 22, n. 11, p. 1–34, 12 abr. 2018.

OKE, A. M. C.; FROST, A. J.; BEESLEY, C. A. **The use of TRMM satellite data as a predictor in the spatial interpolation of daily precipitation over Australia**. 18th World IMACS / MODSIM Congress. **Anais...2009** Disponível em: <<http://mssanz.org.au/modsim09>>

ORGANIZAÇÃO METEOROLÓGICA MUNDIAL. **Guide to meteorological instruments and methods of observation**. 2017 ed. atual. Genebra: Chairperson, 2014. 1177 p. v. Único. Disponível em: https://library.wmo.int/doc_num.php?explnum_id=4147. Acesso em: 3 mar. 2019.

ORGANIZAÇÃO METEOROLÓGICA MUNDIAL. **International Cloud Atlas: manual on the observation of clouds and other meteors**. Genebra: [s. n.], 2018. 1 atlas. Disponível em: <https://cloudatlas.wmo.int/home.html>. Acesso em: 12 fev. 2019.

ORGANIZAÇÃO METEOROLÓGICA MUNDIAL. **Observing systems capability analysis and review tool**. 2019. Disponível em: <https://www.wmo-sat.info/oscar/>. Acesso em: 22 fev. 2019.

PALOMINO-ÁNGEL, S.; ANAYA-ACEVEDO, J. A.; BOTERO, B. A. Evaluation of 3B42V7 and IMERG daily-precipitation products for a very high-precipitation region in northwestern South America. **Atmospheric Research**, v. 217, p. 37–48, mar. 2019.

PELEG, N. *et al.* Spatial variability of extreme rainfall at radar subpixel scale. **Journal of Hydrology**, v. 556, p. 922–933, jan. 2018.

PELTON, Joseph N.; MADRY, Scott; CAMACHO-LARA, Sergio (ed.). **Handbook of satellite applications**. 2ª ed. New York: Springer International Publishing, 2017. 1556 p.

PIANI, C. *et al.* Statistical bias correction of global simulated daily precipitation and temperature for the application of hydrological models. **Journal of Hydrology**, v. 395, n. 3–4, p. 199–215, dez. 2010.

PIANI, C.; HAERTER, J. O.; COPPOLA, E. Statistical bias correction for daily precipitation in regional climate models over Europe. **Theoretical and Applied Climatology**, v. 99, p. 187–192, 29 dez. 2010.

PLOUFFE, C. C. F.; ROBERTSON, C.; CHANDRAPALA, L. Comparing interpolation techniques for monthly rainfall mapping using multiple evaluation criteria and auxiliary data sources: A case study of Sri Lanka. **Environmental Modelling and Software**, v. 67, p. 57–71, maio 2015.

POTTER, N. J. *et al.* Bias in downscaled rainfall characteristics. **Hydrology and Earth System Sciences Discussions**, n. April, p. 1–23, 17 abr. 2019.

QUIRINO, D. T. *et al.* Evaluation of TRMM satellite rainfall estimates (algorithms 3B42 V7 & RT) over the Santo Antônio county (Goiás, Brazil). **Revista Facultad Nacional de Agronomía**, v. 70, n. 3, p. 8251–8261, 2017.

REIS, M.H; GRIEBELER, N.P; SOUZA, P.T.M.; RABELO, M.W.O. Mapeamento de áreas de risco à ocorrência da erosão hídrica no Sudoeste Goiano com base na distribuição espacial de chuvas intensas. **Anais 1º Simpósio de Geotecnologias no Pantanal**. Campo Grande: Embrapa Informática Agropecuária/INPE, p.219-228, 2006.

ROZANTE, J. R. *et al.* Evaluation of TRMM/GPM Blended Daily Products over Brazil. **Remote Sensing**, v. 10, n. 6, p. 1–17, 6 jun. 2018.

SALIO, P. *et al.* Evaluation of high-resolution satellite precipitation estimates over southern South America using a dense rain gauge network. **Atmospheric Research**, v. 163, p. 146–161, set. 2015.

SAPIANO, M. R. P.; ARKIN, P. A. An Intercomparison and Validation of High-Resolution Satellite Precipitation Estimates with 3-Hourly Gauge Data. **Journal of Hydrometeorology**, v. 10, n. 1, p. 149–166, 2009.

SHI, T. *et al.* Spatiotemporal interpolation of rainfall by combining BME theory and satellite rainfall estimates. **Atmosphere**, v. 6, n. 9, p. 1307–1326, 2015.

SILVA, Francisco Eustáquio Oliveira e. **Assimilação do padrão de variabilidade das variáveis de estado de um modelo chuva-vazão em esquemas de simulação/previsão hidrológica**. 2015. Tese (Doutorado em Saneamento, Meio Ambiente e Recursos Hídricos) - Universidade Federal de Minas Gerais, Belo Horizonte, 2015. Disponível em: <http://www.smarh.eng.ufmg.br/bancodefesas.php>. Acesso em: 10 mar. 2019.

SILVA, M. M.; FERREIRA, V. O. Duração da estação chuvosa e ocorrência de veranicos na Bacia do Rio Paraíba. **Geography Department University of Sao Paulo**, v. 29, p. 100–115, 2015.

SOARES, A.; PAZ, A.; PICCILLI, D. Avaliação das estimativas de chuva do satélite TRMM no Estado da Paraíba / Assessment of rainfall estimates of TRMM satellite on Paraíba state. **Revista Brasileira de Recursos Hídricos**, v. 21, n. 2, p. 288–299, 1 abr. 2016.

SOROOSHIAN, S. *et al.* Evaluation of PERSIANN System Satellite-Based Estimates of Tropical Rainfall. **Bulletin of the American Meteorological Society**, v. 81, n. 9, p. 2035–2046, set. 2000.

STRANGWAYS, I. A history of rain gauges. **Weather**, v. 65, n. 5, p. 133–138, maio 2010.

SUN, Q. *et al.* A Review of Global Precipitation Data Sets: Data Sources, Estimation, and Intercomparisons. **Reviews of Geophysics**, v. 56, n. 1, p. 79–107, mar. 2018.

SYED, T. H. *et al.* Analysis of process controls in land surface hydrological cycle over the continental United States. **Journal of Geophysical Research D: Atmospheres**, v. 109, n. 22, p. 1–11, 2004.

SYNODINOS, A. D. *et al.* The impact of inter-annual rainfall variability on African savannas changes with mean rainfall. **Journal of Theoretical Biology**, v. 437, p. 92–100, jan. 2018.

TAPIADOR, F. J. *et al.* Global precipitation measurement: Methods, datasets and applications. **Atmospheric Research**, v. 104–105, p. 70–97, fev. 2012.

TAPIADOR, F. J. *et al.* Global precipitation measurements for validating climate models. **Atmospheric Research**, v. 197, n. May, p. 1–20, nov. 2017.

TAPIADOR, F. J. Measuring Precipitation From Space. In: **Remote Sensing of Aerosols, Clouds, and Precipitation**. [s.l.] Elsevier Inc., 2018. p. 211–221.

TESTIK, Firat Y.; GEBREMICHAEL, Mekonnen. **Rainfall: state of the science**. 1ª ed. Washington: Geophysical Monograph Series, 2010.

TUCCI, Carlos E. M. *et al* (org.). **Hidrologia: ciência e aplicação**. 4ª ed. Porto Alegre: UFRGS/ABRH, 2009. 943 p. v. Único.

UDDIN, S. *et al.* Site-specific precipitation estimate from TRMM data using bilinear weighted interpolation technique: An example from Kuwait. **Journal of Arid Environments**, v. 72, n. 7, p. 1320–1328, jul. 2008.

ULLOA, J. *et al.* Two-step downscaling of TRMM 3b43 V7 precipitation in contrasting climatic regions with sparse monitoring: The case of Ecuador in tropical South America. **Remote Sensing**, v. 9, n. 7, p. 1–23, 2017.

VARMA, A. K. Measurement of Precipitation from Satellite Radiometers (Visible, Infrared, and Microwave): Physical Basis, Methods, and Limitations. In: **Remote Sensing of Aerosols, Clouds, and Precipitation**. [s.l.] Elsevier, 2018. p. 223–248.

VICENTE, G. A.; DAVENPORT, J. C.; SCOFIELD, R. A. The role of orographic and parallax corrections on real time high resolution satellite rainfall rate distribution. **International Journal of Remote Sensing**, v. 23, n. 2, p. 221–230, 2002.

VICENTE, G. A.; SCOFIELD, R. A.; MENZEL, W. P. The Operational GOES Infrared Rainfall Estimation Technique. **Bulletin of the American Meteorological Society**, v. 79, n. 9, p. 1883–1898, 1998.

VILLARINI, G. *et al.* Rainfall and sampling uncertainties: A rain gauge perspective. **Journal of Geophysical Research**, v. 113, n. D11, p. D11102, 4 jun. 2008.

WANG, Pao K. **Physics and dynamics of clouds and precipitation**. 1ª ed. Cambridge: Cambridge University Press, 2013.

WILKS, Daniel S. **Statistical methods in the atmospheric sciences**. 3ª ed. Cambridge: Academic Press, 2011.

WORQLUL, A. W. *et al.* Performance of bias corrected MPEG rainfall estimate for rainfall-runoff simulation in the upper Blue Nile Basin, Ethiopia. **Journal of Hydrology**, v. 556, p. 1182–1191, jan. 2018.

XIE, P. *et al.* Reprocessed, Bias-Corrected CMORPH Global High-Resolution Precipitation Estimates from 1998. **Journal of Hydrometeorology**, v. 18, n. 6, p. 1617–1641, jun. 2017.

YAMAMOTO, Jorge Kazuo; LANDIM, Paulo M. Barbosa (ed.). **Geoestatística: conceitos e aplicações**. 1ª ed. São Paulo: Oficina de Textos, 2013.

YANG, Z. *et al.* Bias adjustment of satellite-based precipitation estimation using gauge observations: A case study in Chile. **Journal of Geophysical Research**, v. 121, n. 8, p. 3790–3806, 2016.

YIN, Z.-Y. *et al.* An Assessment of the Biases of Satellite Rainfall Estimates over the Tibetan Plateau and Correction Methods Based on Topographic Analysis. **Journal of Hydrometeorology**, v. 9, n. 3, p. 301–326, 2008.

YNOUE, Rita Yuri *et al.* **Meteorologia: noções básicas**. 1ª ed. São Paulo: Oficina de Textos, 2017.

ZAMBRANO-BIGIARINI, M. *et al.* Temporal and spatial evaluation of satellite-based rainfall estimates across the complex topographical and climatic gradients of Chile. **Hydrology and Earth System Sciences**, v. 21, n. 2, p. 1295–1320, 2 mar. 2017.

ZENG, Q. *et al.* Inter-comparison and evaluation of remote sensing precipitation products over China from 2005 to 2013. **Remote Sensing**, v. 10, n. 2, 2018.

ZHANG, T. *et al.* Spatial downscaling of TRMM precipitation data considering the impacts of macro-geographical factors and local elevation in the Three-River Headwaters Region. **Remote Sensing of Environment**, v. 215, p. 109–127, 2018.

APÊNDICES




Figura A.1 – Box plots da métrica POD por classes de eventos para todos os SRE.




Figura A.2 – Box plots da métrica FAR por classes de eventos para todos os SRE.




Figura A.3 – Box plots da métrica fBIAS por classes de eventos para todos os SRE.




Figura A.4 – Box plots da componente r na escala diária para todos os SRE.




Figura A.5 – *Box plots* da componente β na escala diária para todos os SRE.




Figura A.6 – *Box plots* da componente γ na escala diária para todos os SRE.




Figura A.7 – Histograma da altimetria da métrica KGE' por estação para o produto CMORPH.




Figura A.8 – Histograma da altimetria da métrica KGE' por estação para o produto TMPA.




Figura A.9 – KGE' mensal por UGH.




Figura A.10 – Componente r da métrica KGE' mensal por UGH.




Figura A.11 – Componente β da métrica KGE' mensal por UGH.




Figura A.12 – Componente γ da métrica KGE' mensal por UGH.




Figura A.13 – Métrica MAE das estações mês a mês.




Figura A.14 – Métrica MAE anual por UGH.




Figura A.15 – Métrica KGE' anual por UGH.

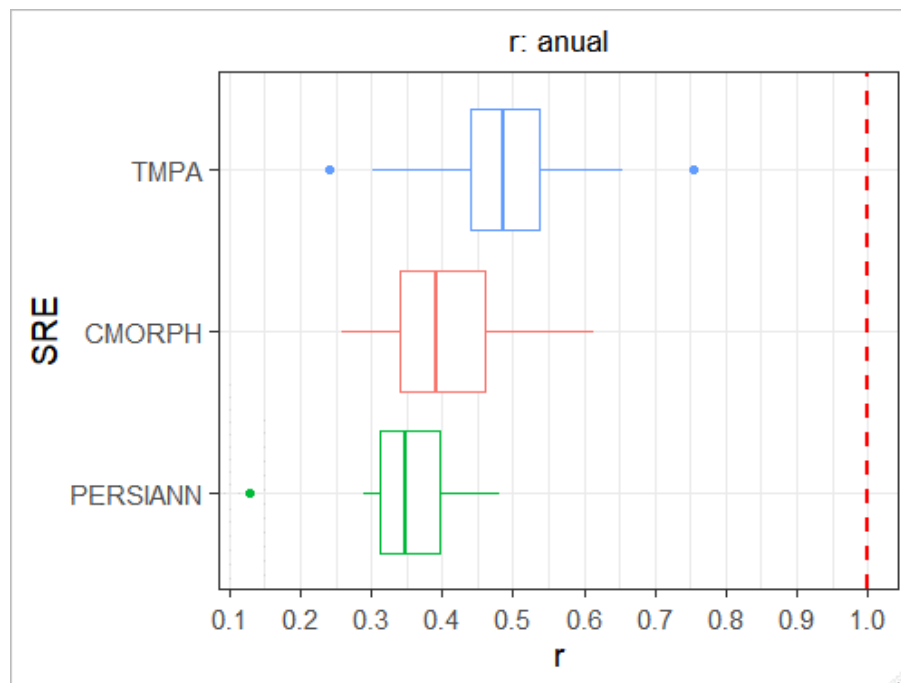


Figura A.16 – Componente r anual por UGH.




Figura A.17 – Componente β anual por UGH.




Figura A.18 – Componente γ anual por UGH.

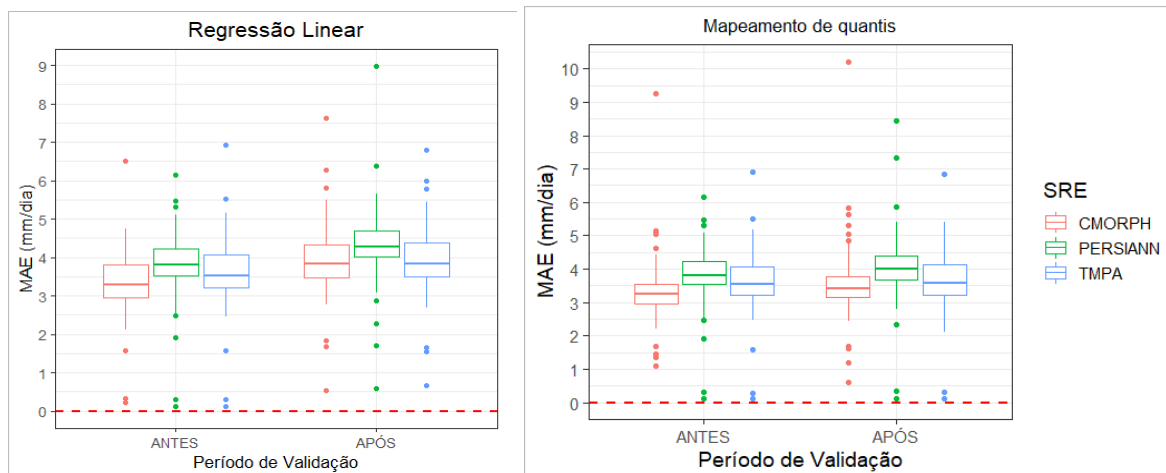


Figura A.19 – Métrica MAE antes e após a correção de viés para todos os SRE na escala diária.




Figura A.20 – Métrica KGE' antes e após a correção de viés na escala diária para todos os SRE.

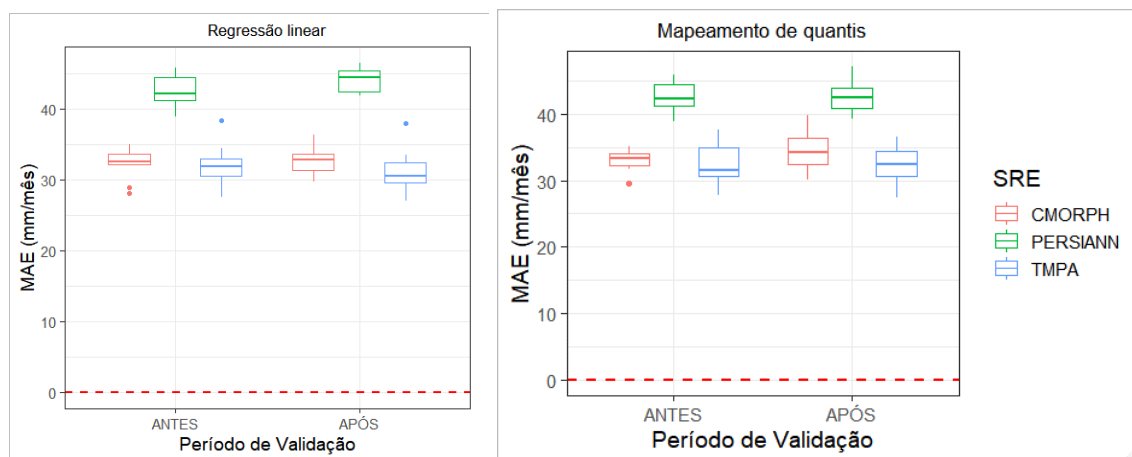


Figura A.21 – Métrica MAE antes e após a correção de viés na escala mensal para todos os SRE.




Figura A.22 – Métrica KGE' antes e após a correção de viés na escala mensal para todos os SRE.




Figura A.23 – Componente r antes e após a correção de viés na escala mensal para todos os SRE.