

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM MEIO AMBIENTE E
RECURSOS HÍDRICOS

AVALIAÇÃO DA PRECIPITAÇÃO ESTIMADA PELO SATÉLITE GPM
PARA A BACIA HIDROGRÁFICA DO RIO SAPUCAÍ

PAOLA DO NASCIMENTO SILVA

ITAJUBÁ

2022

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM MEIO AMBIENTE E
RECURSOS HÍDRICOS

PAOLA DO NASCIMENTO SILVA

AVALIAÇÃO DA PRECIPITAÇÃO ESTIMADA PELO SATÉLITE GPM
PARA A BACIA HIDROGRÁFICA DO RIO SAPUCAÍ

Dissertação submetida ao Programa de Pós-Graduação em Meio Ambiente e Recursos Hídricos como parte dos requisitos para obtenção do título de Mestre em Meio Ambiente e Recursos Hídricos pela Universidade Federal de Itajubá.

Área de Concentração: Meio Ambiente e Recursos Hídricos.

Orientador: Dr. Benedito Cláudio da Silva

ITAJUBÁ

2022

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM MEIO AMBIENTE E
RECURSOS HÍDRICOS

PAOLA DO NASCIMENTO SILVA

AVALIAÇÃO DA PRECIPITAÇÃO ESTIMADA PELO SATÉLITE GPM
PARA A BACIA HIDROGRÁFICA DO RIO SAPUCAÍ

Dissertação aprovada por banca examinadora em 04 de março de 2022, conferindo à autora o título de Mestre em Meio Ambiente e Recursos Hídricos.

Banca examinadora:

Prof. Dr. Benedito Cláudio da Silva (orientador)

Profa. Dra. Vanessa Silveira Barreto Carvalho

Dr. João Bosco Coura dos Reis

ITAJUBÁ

2022

*Aos meus pais, Geralda Lucimar e Lurdurval
(in memoriam).*

AGRADECIMENTOS

À Deus, por me conceder saúde e força para concluir este trabalho, e por ser a minha base em momentos difíceis, especialmente durante esses anos de pandemia da COVID-19, onde eu perdi uma das pessoas mais importantes da minha vida, o meu querido pai.

Aos meus pais, Geralda Lucimar e Lurdurval (in memorian), pelo profundo apoio, paciência e compreensão pela minha ausência em alguns momentos, mas especialmente por acreditar em minha capacidade de vencer cada obstáculo que surgiu no decorrer desses anos. A minha mãe, por ter sido a minha base após a inesperada e dolorosa partida de meu pai.

Ao meu marido, Robson Teodoro, pelo companheirismo, incentivo, carinho, paciência e cuidado comigo durante todo o período do mestrado, principalmente após a perda do meu pai.

Ao meu orientador, Dr. Benedito Cláudio da Silva, pela confiança depositada em mim e por acreditar em minha capacidade para concluir esse projeto, além da transmissão de conhecimentos fundamentais para a elaboração do mesmo.

À todos os professores, que ao decorrer do mestrado se mostraram dedicados e pacientes para compartilhar seus conhecimentos.

Aos meus colegas de mestrado, que dividiram essa jornada comigo com muito companheirismo. Em especial a Aline Freitas, por todo o auxílio em momentos de dúvidas, pela disponibilidade em me ouvir e aconselhar, e pela ajuda em tornar essa jornada mais leve.

À CAPES, pela concessão da bolsa de mestrado.

Por fim, agradeço a todos que de certa forma contribuíram direta ou indiretamente para a realização desse projeto.

RESUMO

No Brasil, a quantidade de estações pluviométricas em superfície ainda é baixa e não é o suficiente para representar a variabilidade espaço-temporal da precipitação em todo o território. Logo, uma boa opção para suprir essa insuficiência de dados é a utilização de estimativas de precipitação por satélites. Sendo assim, esse estudo teve como objetivo validar, por meio de métodos estatísticos, a precipitação diária estimada pelo satélite *Global Precipitation Measurement* (GPM) para a Bacia Hidrográfica do Rio Sapucaí, utilizando quatro metodologias: ponto a pixel – dados originais, sem passar por nenhum processamento; pixel a ponto – dados do satélite com viés removido; pixel a pixel – dados da estação interpolados; média na área – média nas subáreas do Alto, Médio e Baixo Sapucaí. Os dados utilizados na validação foram provenientes de estações pluviométricas da Agência Nacional de Águas e Saneamento Básico (ANA). Os resultados encontrados para a metodologia ponto a pixel para a série completa, verão e inverno, indicaram a existência de uma correlação média moderada, com erros variando da magnitude de 3 a 10 mm dia⁻¹ e com uma tendência média de superestimativa do GPM em relação aos dados da ANA. O mesmo ocorreu para o método pixel a ponto, onde os resultados foram muito semelhantes, além disso, observou-se uma correção na frequência de precipitação por meio dessa metodologia. O método pixel a pixel apresentou resultados estatísticos mais altos, comparado aos anteriores, e ainda aumentou a cobertura de dados em superfície. No entanto, a metodologia de média na área foi a que obteve os melhores resultados: correlação alta, coeficiente de determinação acima de 60% e magnitude de erros mais baixos. No geral, em ambos os casos o GPM apresentou uma tendência média de superestimativa dos dados da ANA, porém se mostrou viável na utilização em estudos, principalmente como forma de suprir a necessidade de dados em locais sem registros.

Palavras-chave: GPM. ANA. Precipitação. Rio Sapucaí. Estatísticas.

ABSTRACT

In Brazil, the number of rainfall stations on the surface is still low and is not enough to represent the spatio-temporal variability of rainfall throughout the territory. Therefore, a good option to overcome this lack of data is the use of satellite precipitation estimates. Therefore, this study aimed to validate, through statistical methods, the daily precipitation estimated by the Global Precipitation Measurement (GPM) satellite for the Sapucaí River Basin, using four methodologies: point by pixel - original data, without going through no processing; pixel to point – debiased satellite data; pixel by pixel – interpolated station data; average in the area – average in the sub-areas of Alto, Medio and Baixo Sapucaí. The data used in the validation came from rainfall stations of the National Agency for Water and Basic Sanitation (ANA). The results found for the point-to-pixel methodology for the complete series, summer and winter, indicated the existence of a moderate average correlation, with errors varying from magnitude of 3 to 10 mm day⁻¹ and with an average tendency to overestimate the GPM in relation to ANA data. The same occurred for the pixel-to-point method, where the results were very similar, in addition, a correction in the precipitation frequency was observed through this methodology. The pixel-by-pixel method presented higher statistical results, compared to the previous ones, and even increased the surface data coverage. However, the averaging methodology in the area was the one that obtained the best results: high correlation, coefficient of determination above 60% and lower magnitude of errors. Overall, in both cases the GPM showed an average tendency to overestimate the ANA data, but it proved to be viable for use in studies, mainly as a way to meet the need for data in places without records.

Keywords: GPM. ANA. Precipitation. Sapucaí River. Statistics.

LISTA DE FIGURAS

Figura 1 – Mapa da localização da área de estudo.....	22
Figura 2 – Mapa hipsométrico da BHRS.....	23
Figura 3 – Mapa da localização das estações pluviométricas utilizadas no estudo.....	26
Figura 4 – Fluxograma da metodologia utilizada no estudo.....	27
Figura 5 – Média mensal de precipitação na BHRS.....	32
Figura 6 – Acumulado anual de precipitação na BHRS.....	33
Figura 7 – Métricas estatísticas calculadas para a série completa: a) Correlação de Pearson; b) R^2 ; c) MAE; d) RMSE; e) BIAS.....	36
Figura 8 – Mapas das estatísticas calculadas para a série completa: a) Correlação de Pearson; b) R^2 ; c) MAE; d) RMSE; e) BIAS.....	37
Figura 9 – Métricas estatísticas de contingência para a série completa, considerando diferentes intervalos de precipitação.....	40
Figura 10 – Métricas estatísticas calculadas para a estação de verão: a) Correlação de Pearson; b) R^2 ; c) MAE; d) RMSE; e) BIAS.....	43
Figura 11 – Mapas das estatísticas calculadas para a estação de verão: a) Correlação de Pearson; b) R^2 ; c) MAE; d) RMSE; e) BIAS.....	44
Figura 12 – Métricas estatísticas calculadas para a estação de inverno: a) Correlação de Pearson; b) R^2 ; c) MAE; d) RMSE; e) BIAS.....	48
Figura 13 – Mapas das estatísticas calculadas para a estação de inverno: a) Correlação de Pearson; b) R^2 ; c) MAE; d) RMSE; e) BIAS.....	49
Figura 14 – Curvas de permanência para cada ponto antes da interpolação.....	52
Figura 15 – Curvas de permanência para cada ponto antes da interpolação.....	53
Figura 16 – Curvas de permanência para cada ponto depois da interpolação.....	54
Figura 17 – Curvas de permanência para cada ponto depois da interpolação.....	55

Figura 18 – Métricas estatísticas calculadas para a série completa, pela metodologia pixel a ponto: a) Correlação de Pearson; b) R^2 ; c) MAE; d) RMSE; e) BIAS.....	58
Figura 19 – Mapas das estatísticas pelo método pixel a ponto: a) Correlação de Pearson; b) R^2 ; c) MAE; d) RMSE; e) BIAS.....	59
Figura 20 – Mapas das estatísticas pelo método pixel a pixel: a) Correlação de Pearson; b) R^2 ; c) MAE; d) RMSE; e) BIAS.....	63
Figura 21 – Mapa da BHRS com as divisões em: Alto Sapucaí (caixa vermelha), Médio Sapucaí (caixa verde) e Baixo Sapucaí (caixa azul).....	64

LISTA DE TABELAS

Tabela 1 – Informações das estações pluviométricas da ANA.....	25
Tabela 2 – Média 1 entre as estações de pixel coincidente.....	28
Tabela 3 – Média 2 entre as estações de pixel coincidente.....	28
Tabela 4 – Variáveis apresentadas nas estatísticas de contingência.....	29
Tabela 5 – Informações das estações da ANA e valores das estatísticas calculadas para a série completa para avaliar o desempenho da precipitação diária do GPM em relação a ANA. Destacados em vermelho (azul) indicam pior (melhor) desempenho.....	38
Tabela 6 – Valores das estatísticas de contingência para cada intervalo de precipitação.....	40
Tabela 7 – Informações das estações da ANA e valores das estatísticas calculadas para o verão para avaliar o desempenho da precipitação diária do GPM em relação a ANA. Destacados em vermelho (azul) indicam pior (melhor) desempenho.....	45
Tabela 8 – Informações das estações da ANA e valores das estatísticas calculadas para o inverno para avaliar o desempenho da precipitação diária do GPM em relação a ANA. Destacados em vermelho (azul) indicam pior (melhor) desempenho.....	50
Tabela 9 – Informações das estações da ANA e valores das estatísticas calculadas para o método pixel a ponto, para avaliar o desempenho da precipitação diária do GPM em relação a ANA. Destacados em vermelho (azul) indicam pior (melhor) desempenho.....	60
Tabela 10 – Valores das estatísticas calculadas para cada subárea.....	65
Tabela 11 – Valores médios das estatísticas para cada método aplicado no estudo...	66

LISTA DE QUADROS

Quadro 1 – Métricas estatísticas utilizadas na comparação entre os dados.....	30
Quadro 2 – Métricas estatísticas de contingência utilizadas na comparação entre os dados.....	30

LISTA DE ABREVIATURAS E SIGLAS

AESA – Agência Executiva de Gestão das Águas do Estado da Paraíba

ANA – Agência Nacional de Águas e Saneamento Básico

BHRS – Bacia Hidrográfica do Rio Sapucaí

CERES – *Clouds and the Earth's Radiant Energy System*

CNES – *Centre National D'études Spatiales*

CONUS – *Continental United States*

CPC – *Climate Prediction Center*

CSI – Índice de Sucesso Crítico

Cwa – Clima subtropical úmido

Cwb – Clima subtropical de altitude

DPR – *Dual-frequency precipitation radar*

EUMETSAT – *European Organisation for the Exploitation of Meteorological Satellites*

FAR – Taxa de Alarme Falso

GMI – *GPM Microwave Imager*

GOES – *Geostationary Operational Environmental Satellite*

GPM – *Global Precipitation Measurement*

IMERG – *Integrated Multi-satellitE Retrievals*

INMET – Instituto Nacional de Meteorologia

IQD – Inverso do Quadrado da Distância

ISRO – *Indian Space Research Organisation*

JAXA – *Japan Aerospace Exploration Agency*

LIS – *Lightning Imaging Sensor*

MAE – Erro Médio Absoluto

MG – Minas Gerais

NASA – *National Aeronautics and Space Administration*

NMM – Nível médio do mar

NOAA – *National Oceanic and Atmospheric Administration*

POD – Probabilidade de Detecção

POES – *Polar Operational Environmental Satellites*

PR – *Precipitation Radar*

PRISM – *Parameter-Elevation Regressions on Independent Slopes Model*

R² – Coeficiente de Determinação

RMSE – Raiz do Erro Médio Quadrático

SP – São Paulo

SPI – *Standard Precipitation Index*

TMI – *Microwave Imager*

TMPA - RT – TRMM Multi-satellite Precipitation Analysis - Real-Time

TMPA V7 – TRMM Multi-satellite Precipitation Analysis - Version 7

TRMM – *Tropical Rainfall Measuring Mission*

UTC – *Coordinated Universal Time*

VIRS – *Visible and Infrared Scanner*

ρ – Correlação de Pearson

SUMÁRIO

1 INTRODUÇÃO	13
2 OBJETIVOS	20
2.1 Objetivo geral	20
2.2 Objetivos específicos	20
3 MATERIAL E MÉTODOS	20
3.1 Área de estudo	20
3.2 Dados de estações pluviométricas em solo	24
3.3 Dados GPM-IMERG	26
3.4 Métodos	27
4 RESULTADOS E DISCUSSÕES	32
4.1 Caracterização da Precipitação na BHRS	32
4.2 Análise Ponto a Pixel	33
4.2.1 Análise da série completa (04/2014 a 12/2019)	33
4.2.2 Análise para a estação de verão	40
4.2.3 Análise para a estação de inverno	46
4.3 Análise Pixel a Ponto	51
4.4 Análise Pixel a Pixel	61
4.5 Análise por Média na Área	63
4.6 Comparação entre as quatro análises	65
5 CONCLUSÃO	66
6 REFERÊNCIAS	68

1 INTRODUÇÃO

A precipitação é uma das variáveis mais importantes no ciclo hidrológico, pois atua como um mecanismo de retorno da água para a superfície. O excesso ou o déficit de precipitação por um longo período de tempo pode levar a ocorrências de eventos extremos como inundações e secas (TWARDOSZ; CEBULSKA; WALANUS, 2016). As inundações são eventos considerados perigosos para a população, devido a exposição ao risco de perdas de vidas e danos em propriedades. Já a falta de precipitação, ocasiona eventos de seca, que podem afetar setores como a agricultura e, conseqüentemente, reduzir a quantidade de alimentos disponíveis para os seres humanos (KIDD; HUFFMAN, 2011). Diante desses fatos, saber onde, quando e quanto chove é fundamental para compreender melhor como o sistema terrestre funciona e também para melhorar a previsão de tempo, de clima, dos recursos hídricos e de eventos extremos, tais como secas e inundações (HOU *et al.*, 2014).

Visto a importância da variável precipitação, é essencial a sua medição precisa para estudos nas áreas de hidrologia, meteorologia, entre outros (LU *et al.*, 2019), porém, à alta variabilidade no tempo e no espaço traz dificuldades a esse processo (KUMMEROW *et al.*, 2000). Além disso, a escassez de estações pluviométricas no Brasil, principalmente em lugares de difícil acesso, se tornou um problema para os estudos na área de hidrologia.

No Brasil, o monitoramento da precipitação da Agência Nacional de Águas e Saneamento Básico (ANA) teve início no ano de 1855 e, atualmente conta com uma rede de 2.767 estações pluviométricas (<http://www.snirh.gov.br/hidroweb/apresentacao>), já o Instituto Nacional de Meteorologia (INMET) começou o monitoramento de variáveis meteorológicas em 1909, e nos dias de hoje conta com mais de 400 estações meteorológicas convencionais e automáticas (<https://portal.inmet.gov.br/sobre-meteorologia>). Mesmo com mais de 100 anos de observações no Brasil, a maior parte das estações pluviométricas possuem apenas dados mais recentes, o que acaba dificultando a obtenção de séries históricas mais longas. Além disso, o número de estações ainda é baixo, considerando toda a extensão continental do país, e não consegue representar com detalhes a variabilidade temporal e espacial da precipitação em todo o território brasileiro (TORRES *et al.*, 2020).

A baixa densidade de estações pluviométricas em superfície, principalmente em regiões no interior do Brasil e em áreas de difícil acesso, acabou se tornando um problema para estudos hidrológicos, pois a ocorrência de precipitação, em áreas da bacia hidrográfica sem estações meteorológicas, pode não ser contabilizada pela estação mais próxima, influenciando negativamente nas análises de escoamento superficial, de déficit hídrico e de balanço de energia (PEREIRA *et al.*, 2013). Nesse contexto, uma opção para suprir essa insuficiência de dados é a utilização de estimativas de precipitação por satélites, tornando possível a observação da chuva de forma contínua no tempo e no espaço (CONDOM; RAU; ESPINOZA, 2011; ALVES *et al.*, 2017).

Através da utilização dos satélites é possível estimar parâmetros e fluxos ligados aos processos hidrológicos, tais como umidade do solo, evapotranspiração, precipitação, dentre outros. Segundo Pereira *et al.* (2013), na década de 90 foi lançado o primeiro satélite de radar aerotransportado, onde o seu objetivo era de coletar dados mais refinados a respeito da estrutura da precipitação. O *Tropical Rainfall Measuring Mission* (TRMM) foi um projeto em parceria entre a *National Aeronautics and Space Administration* (NASA) e a *Japan Aerospace Exploration Agency* (JAXA), e teve seu lançamento em 27 de novembro de 1997 na Ilha de Tanegashima (KUMMEROW *et al.*, 2000). Esse satélite possui órbita oblíqua não-heliossíncrona baixa (403 km), com período de translação de 91 minutos, com dados estimados a cada 3 horas, e resolução espacial de $0,25^\circ$ que varia de 35° N a 35° S. Além disso, o TRMM possuía 5 diferentes instrumentos a bordo, denominados sensores, capazes de atuar em diferentes faixas do espectro eletromagnético, sendo estes: (1) um imageador de micro-ondas (TMI) – sensor de micro-ondas passivo projetado para fornecer informações quantitativas de precipitação sobre uma ampla área do satélite; (2) um radar de precipitação (PR) – primeiro instrumento espacial para fornecer mapas tridimensionais da estrutura de uma tempestade; (3) um radiômetro no visível e no infravermelho (VIRS) – também fornece indicação da chuva, e se conecta com as observações do *Geostationary Operational Environmental Satellite* (GOES) e outros como o *Polar Operational Environmental Satellites* (POES); (4) um sensor de energia radiante da superfície terrestre e de nuvens (CERES) – monitora a energia trocada entre o sol, a atmosfera terrestre, a superfície e nuvens, e o espaço; e (5) um sensor para imageamento de relâmpagos (LIS) – instrumento altamente sofisticado capaz de

detectar e localizar um relâmpago na região tropical (PASSOW, 2010; NASTOS; KAPSOMENAKIS; PHILANDRAS, 2016; ALVES et al., 2017).

Os dados de todos os instrumentos a bordo do TRMM começaram a ser disponibilizados cerca de 30 dias após o seu lançamento (KUMMEROW *et al.*, 2000). O satélite contribuiu para a melhoria da compreensão da estrutura e evolução de ciclones tropicais, para as propriedades de sistemas convectivos, as relações relâmpago-tempestade, modelagem climática e meteorológica e os impactos humanos na precipitação, além disso, ainda era possível monitorar enchentes e secas e auxiliar a previsão de tempo. Esse satélite teve o seu instrumento VIRS desligado em março de 2014, a fim de poupar a vida útil da bateria do satélite, e em julho do mesmo ano, o satélite começou a decair lentamente devido à escassez de combustível, porém ainda coletava dados. Foi no ano de 2015, no início de março, que o combustível se esgotou completamente. Deste modo, após 17 anos de funcionamento a missão TRMM chegou ao fim, parando com a coleta de dados em 8 de abril de 2015 (GPM, 2015).

A desativação do TRMM não foi o fim das observações de ciclones e precipitação através do espaço. No dia 27 de fevereiro de 2014, da Ilha de Tanegashima, foi lançado o observatório central da missão *Global Precipitation Measurement* (GPM), que também é produto de uma parceria entre a NASA e a JAXA. Essa missão é composta pelo observatório central GPM e compreende um consórcio de agências espaciais internacionais, incluindo o Centro Nacional de Estudos Espaciais (CNES), a Organização de Pesquisa Espacial da Índia (ISRO), a Administração Oceânica e Atmosférica Nacional (NOAA), a Organização Europeia para a Exploração de Satélites Meteorológicos (EUMETSAT) e outros (GPM, 2020a).

O observatório central do GPM, que carrega dois instrumentos a bordo para estimar a precipitação e servir como padrão para a calibração dos outros membros da constelação de satélites GPM, opera em órbita baixa circular não síncrona (408 km), e se estende desde 65° N a 65° S, ou seja, consegue atingir latitudes mais elevadas que não eram observadas pelo TRMM. Os seus instrumentos a bordo são: (1) um gerador de imagens GPM de micro-ondas multicanal de varredura cônica – GPM *Microwave Imager* (GMI; as frequências variam entre 10 e 183 GHz) que estima a precipitação tanto leve quanto forte; e (2) um radar de precipitação de dupla frequência ativo (DPR; banda Ku a 13,6 GHz e banda Ka a 35,5 GHz) que fornece estimativas

tridimensionais da estrutura e características da precipitação (ASONG *et al.*, 2017; GPM, 2020b).

O satélite GPM disponibiliza diversos produtos de estimativas de precipitação denominadas por GPM-IMERG (*Integrated Multi-satellitE Retrievals*), que possui resolução temporal e espacial de 30 minutos e $0,1^\circ$, respectivamente (TORRES *et al.*, 2020). Esses produtos são divididos em 3 níveis, no qual o nível 1 apresenta os dados mais brutos, já os níveis 2 e 3 apresenta os dados mais processados. No nível 3, são utilizadas as estimativas da constelação do GPM, radares e uma rede de postos pluviométricos em superfície para realizar os ajustes finais (GADÊLHA, 2018). Existem três tipos de produtos IMERG, onde a cada ano uma versão atual desse conjunto de dados é disponibilizada, são eles: (1) *Early run* (rodada recente) – disponibilizado cerca de quatro horas após a captura das informações pelos satélites; (2) *Late run* (rodada tardia) – disponibilizado cerca de doze horas após; e (3) *Final run* (rodada final) – disponibilizado cerca de quatro meses após. Os dois primeiros produtos são geralmente destinados a previsões de eventos de grandes impactos e que precisam de informações em tempo real, tais como enchentes e outras condições de risco, enquanto que o último é mais apropriado para fins de pesquisas (OMRANIAN; SHARIF, 2018).

O principal diferencial do GPM em relação ao TRMM é a capacidade de estimar as chuvas leves ($<0,5 \text{ mm h}^{-1}$), a neve e as propriedades microfísicas das partículas precipitantes. Destaca-se como ponto positivo da substituição do TRMM pelo GPM a possibilidade de obter um melhor conhecimento do ciclo da água e a sua relação com as mudanças climáticas, das estruturas de tempestades, da microfísica da precipitação; além disso, ainda possui recursos estendidos para o monitoramento e previsão de ciclones tropicais e outros eventos climáticos extremos, melhoria na previsão de safras agrícolas e monitoramento dos recursos de água doce, entre outros (GPM, 2020a).

Apesar da estimativa por satélites ser a melhor alternativa para minimizar a falta dos dados em superfície, seus erros e incertezas geram algumas limitações em seu uso. Segundo Hashemi *et al.* (2017), estudos mostraram que as estimativas de precipitação por satélite possuem uma alta dependência com a elevação da superfície terrestre e a topografia. Isso se dá devido ao efeito orográfico nas taxas de precipitação (ANDERS *et al.*, 2006).

Diante das incertezas apresentadas pelos satélites, diversos estudos foram desenvolvidos com a finalidade de verificar a confiabilidade das estimativas por satélite e quais os possíveis erros que poderiam apresentar. Hashemi *et al.* (2017) compararam os dados de precipitação estimada pelo TRMM 3B43 com dados do CPC (*Climate Prediction Center*) e da estimativa do PRISM (*Parameter-Elevation Regressions on Independent Slopes Model*), para toda a região do CONUS (*Continental United States*) no período de 1998 a 2015. Os resultados mostraram que o satélite subestimava a precipitação em áreas de altitudes acima de 1500 m acima do nível médio do mar (NMM), onde grande parte eram áreas montanhosas. Além disso, os meses de inverno foram os que mais subestimaram a precipitação devido ser a estação mais úmida na região. Deste modo, os autores desenvolveram um modelo de correção e puderam concluir que com esse modelo houve uma melhora significativa nos dados estimados por satélites, especialmente nas altitudes mais elevadas, onde o erro era maior devido ao efeito orográfico.

Nastos, Kapsomenakis e Philandras (2016) avaliaram a confiabilidade da estimativa de precipitação da versão 7 do TRMM 3B43 em relação aos dados de estação em solo, para a Grécia, no período de 1998 a 2008. Os resultados mostraram uma correlação alta (0,90) entre os dados nos meses de inverno, exceto em regiões montanhosas, já nas outras estações a correlação foi baixa principalmente em altas altitudes. Os autores então concluíram que o satélite subestimava a precipitação em altas altitudes e superestimava em altitudes mais baixas e regiões costeiras, e também que o desempenho do satélite é consideravelmente fraco na região da Grécia quando há acumulado mensal elevado de precipitação.

Yuan *et al.* (2017) avaliaram os produtos de precipitação dos satélites TRMM e GPM em simulações de fluxo, para a bacia do Rio Chindwin em Mianmar no período de abril de 2014 a dezembro de 2015. Os principais resultados mostraram que ambos os satélites possuem erros consideráveis quando comparados com dados de pluviômetros, onde o IMERG subestimou os dados de todos os medidores, já o 3B42 V7 subestimou moderadamente os dados de três dos cinco medidores. No geral, ambos os produtos tiveram um desempenho fraco em detectar as estimativas, tanto de chuva forte quanto leve, porém ainda são viáveis na utilização de simulações de fluxo na bacia de estudo, sendo o satélite TRMM mais adequado do que o GPM. Os

autores também destacaram a necessidade de uma refinação dos algoritmos e melhora da precisão dos produtos IMERG para Mianmar.

Zubieta *et al.* (2017) avaliaram três conjuntos de dados de precipitação por satélite (GPM-IMERG – *Final run*, TMPA V7 e TMPA RT) em comparação com um conjunto de dados baseado em solo na bacia Amazônica do Peru e Equador, para o período de março de 2014 a junho de 2015. Os autores encontraram que os dados GPM-IMERG e TMPA V7 superestimam a precipitação observada em solo em 11,1% e 15,7%, respectivamente. Também concluíram que o GPM-IMERG é igualmente útil aos dados TMPA V7 e TMPA RT para estudos nas regiões do sul (bacia de Ucayali) e que ambos não simulam adequadamente vazões nas regiões do norte (bacias do Marañón e Napo).

Gadêlha (2018) realizou uma comparação entre os dados do GPM, produto *Final Run*, e de estações pluviométricas de diferentes agências, através de estatísticas para o ano de 2016. Essa comparação se deu de 3 formas: pixel a pixel, média para todo o Brasil e média em subáreas; para a escala de tempo diária, mensal e anual. Os resultados encontrados para o método pixel a pixel foram que os piores valores das estatísticas foram para a escala diária, já a mensal houve uma boa melhora e com a anual verificou-se uma tendência de superestimativa do GPM. Para o método média nacional, os resultados, em geral, ficaram melhores. E novamente, para a escala mensal os valores ficaram melhores do que para a diária, enquanto que para a anual houve uma pequena subestimativa do GPM. Por último, para o método média das subáreas, para a escala diária os melhores valores foram para as regiões centro-oeste e sudeste. Para a escala mensal, os resultados das estatísticas foram melhores, e a região sul apresentou os valores mais baixos. Já na escala anual, foi possível observar valores muito próximos entre o GPM e as estações. De acordo com o autor, os dados do GPM em escala diária apresentaram falhas consideráveis, enquanto que os dados mensais ficaram mais próximos dos dados observados.

Lopes (2020) comparou os dados do GPM (*Final Run*) com dados de estações pluviométricas (ANA e AESA – Agência Executiva de Gestão das Águas do Estado da Paraíba) por meio de estatísticas para a sub-bacia do Rio Piancó-Paraíba. A metodologia utilizada para comparação foi a ponto a pixel e os resultados encontrados apontam para uma superestimação do GPM, porém uma boa correlação para a região central e de norte a sul da sub-bacia.

Logo, os produtos de precipitação por satélite são viáveis para estudos, porém tendem a conter erros sistemáticos e precisam de correções para se aproximarem dos valores observados em superfície. Um outro ponto que também deve ser levado em consideração é sua resolução espacial e temporal, pois pode acabar limitando a sua aplicação em estudos hidrometeorológicos (HASHEMI et al., 2020), especialmente em pequenas bacias hidrográficas.

Outros estudos, com diferentes finalidades, utilizam dados de precipitação. Por exemplo Silva *et al.* (2020), que estudaram as características anômalas do verão de 2019 para o Sudeste brasileiro. Neste estudo, o principal objetivo era identificar quais eram os padrões atmosféricos no verão de 2019 e como isso causou uma anomalia da precipitação para essa estação do ano. Freitas *et al.* (2022) avaliaram a seca na bacia do Rio São Francisco, cujos objetivos eram, através do SPI (*Standard Precipitation Index*), identificar eventos hidrológicos de seca em cada sub-região da bacia e analisar, para a região com seca mais longa e severa, os padrões atmosféricos e oceânicos anômalos associados a meses secos dentro da estação chuvosa. Santos *et al.* (2017) avaliaram as frequências de eventos extremos de seca e chuva na Amazônia, utilizando o SPI, com diferentes bancos de dados de precipitação, e os autores acreditam que esse estudo seja útil para o planejamento de atividades como o zoneamento de práticas agrícolas, o gerenciamento de recursos hídricos e a transmissão e distribuição de energia elétrica. Santos, Cunha e Ribeiro-Neto (2019) avaliaram dados de precipitação para o monitoramento do padrão espaço-temporal da seca no Nordeste brasileiro, e como a falta de dados de longo prazo da precipitação em solo é um obstáculo, esse estudo teve como objetivo avaliar o desempenho espaço-temporal de duas fontes de dados (observacionais interpolados e sensoriamento remoto) com finalidade de criar um banco de dados para caracterizar e monitorar a seca no Nordeste.

Diante de todos os trabalhos já citados, nota-se a importância da variável precipitação, uma vez que a mesma pode ser utilizada em diversas pesquisas com diferentes finalidades. Deste modo, destaca-se a importância de desenvolver trabalhos que avaliem produtos de precipitação por sensoriamento remoto e encontre se o seu uso é viável em estudos, uma vez que a mesma é capaz de suprir a necessidade de dados onde não existem estações pluviométricas.

Para desenvolver o presente estudo, escolheu-se a bacia hidrográfica do Rio Sapucaí (BHRS) para realizar as comparações estatísticas entre os produtos de precipitação do GPM e as estações pluviométricas da ANA.

2 OBJETIVOS

2.1 Objetivo geral

O objetivo geral do presente trabalho é de avaliar o desempenho dos dados de precipitação estimados pelo satélite GPM sobre a bacia hidrográfica do Rio Sapucaí, em comparação com dados de estações pluviométricas em solo.

2.2 Objetivos específicos

- Aplicar quatro metodologias de comparação entre os dados das estações pluviométricas e as estimativas do satélite GPM;
- Avaliar um método de correção de erros sistemáticos nas estimativas do GPM;
- Avaliar o desempenho das estimativas do GPM para diferentes escalas espaciais.

3 MATERIAL E MÉTODOS

3.1 Área de estudo

A área selecionada para aplicar este estudo foi a BHRS. Essa bacia está localizada na região Sudeste do país – considerada a região mais rica, pois é onde concentra-se mais de 65% do PIB (Produto Interno Bruto) nacional (IBGE, 2019). A sua economia é regida principalmente pelo ramo da indústria, agricultura e pecuária, além disso, comporta mais de 42% de toda a população brasileira (IBGE, 2021).

Na BHRS, são frequentes os episódios de inundações – definidas como o extravasamento da cota máxima de um curso d'água e que atinge a planície de inundação (REBOITA; SILVA C.; SILVA V., 2019). Autores como Pinheiros (2005) e Barbosa, Oliveira M. e Oliveira J. (2015) apresentaram um histórico de inundações

ocorridas no município de Itajubá, localizado no interior da bacia, para os períodos de 1819 a 2000 e 1930 a 2011, e ambos constataram que esses episódios se concentram entre os meses de outubro a março (período chuvoso na região). Um outro trabalho que também analisou duas grandes cheias para o município de Itajubá, ocorridas nos anos de 1991 e 2000, foi o de Reboita et al. (2017), onde concluíram-se que o elevado volume de chuva foi ocasionado, principalmente, devido a atuação da Zona de Convergência do Atlântico Sul (ZCAS) – caracterizada por uma banda persistente de nebulosidade e precipitação orientada no sentido noroeste-sudeste, que se estende da Amazônia, cruza o Sudeste e atinge o sudoeste do oceano Atlântico (KODAMA, 1992; QUADRO, 1999; HERDIES *et al.*, 2002; CARVALHO; JONES; LIEBMANN, 2004; AMBRIZZI; FERRAZ, 2015; SILVA; ESCOBAR; REBOITA, 2020).

Diante dos fatos relatados, nota-se a importância da BHRS, deste modo, traremos informações relevantes sobre ela. A BHRS compreende parte dos estados de Minas Gerais (MG) e São Paulo (SP) (Figura 1) e integra a bacia do Rio Grande. Sua área de drenagem é de 9.456 km² e segundo Almeida *et al.* (2017) o rio Sapucaí nasce na cidade de Campos do Jordão – SP, que fica localizado na Serra da Mantiqueira e possui altitude de 1620 m, e percorre 248 km até desaguar entre as cidades de Três Pontas e Paraguaçu, no Lago de Furnas – MG, onde a altitude é de 780 m.

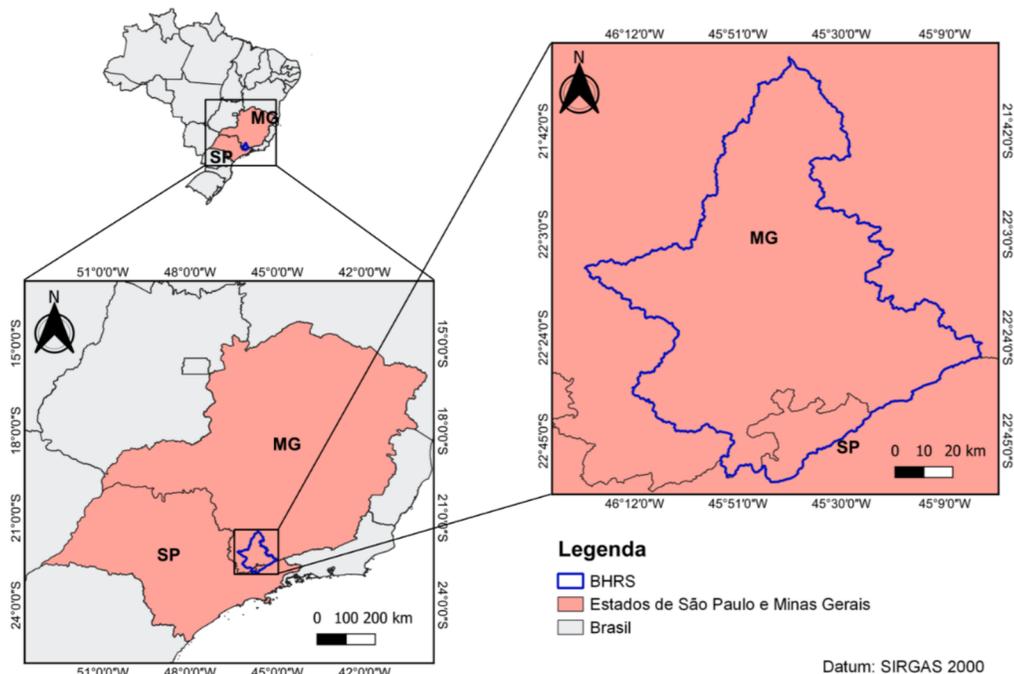


Figura 1 – Mapa da localização da área de estudo

A BHRs compreende 51 municípios, sendo que 48 deles estão localizados no estado de MG, e os outros três encontram-se no estado de SP. A vertente mineira possui uma população estimada em mais de 708 mil habitantes, sendo 74,4% urbana e 25,6% rural, e a sua área de drenagem é de 8.824 km², o que representa 93,32% do total. Já a vertente paulista possui uma população estimada em mais de 61 mil habitantes e uma área de drenagem de 632 km², o que representa 6,68% do total (COPASA, 2010). Segundo Sá Junior *et al.* (2012), de acordo com a classificação de Köppen, o clima na região pode ser classificado como Cwa – clima subtropical úmido, com inverno seco e verão quente; e Cwb – clima subtropical de altitude, com inverno seco e verão moderadamente quente. Esse padrão de um período chuvoso e outro seco na bacia é característico do Sistema de Monção da América do Sul (VERA *et al.*, 2006; REBOITA *et al.*, 2010). A região das cabeceiras da bacia sofre bastante influência da orografia da Serra da Mantiqueira, com chuvas bem distribuídas em todos os meses do ano – reduzindo no inverno, onde a temperatura média anual é de aproximadamente 15,3 °C e a precipitação média anual é superior a 1.700 mm; nas demais áreas da bacia, as temperaturas permanecem amenas durante todo o ano, com médias anuais entre 18 °C e 19 °C, e com precipitação média anual de 1.500

mm, podendo ocorrer ausência de chuva por um ou dois meses (ALMEIDA et al., 2017).

As altitudes dentro da BHRS variam entre 750 e 2.349 m (Figura 2). De acordo com a Figura 2, é na região do Alto Sapucaí que se encontram as maiores altitudes, principalmente no limite da bacia, onde se localiza a Serra da Mantiqueira. No Baixo Sapucaí encontram-se as menores altitudes, que variam entre 750 e 1.050 m.

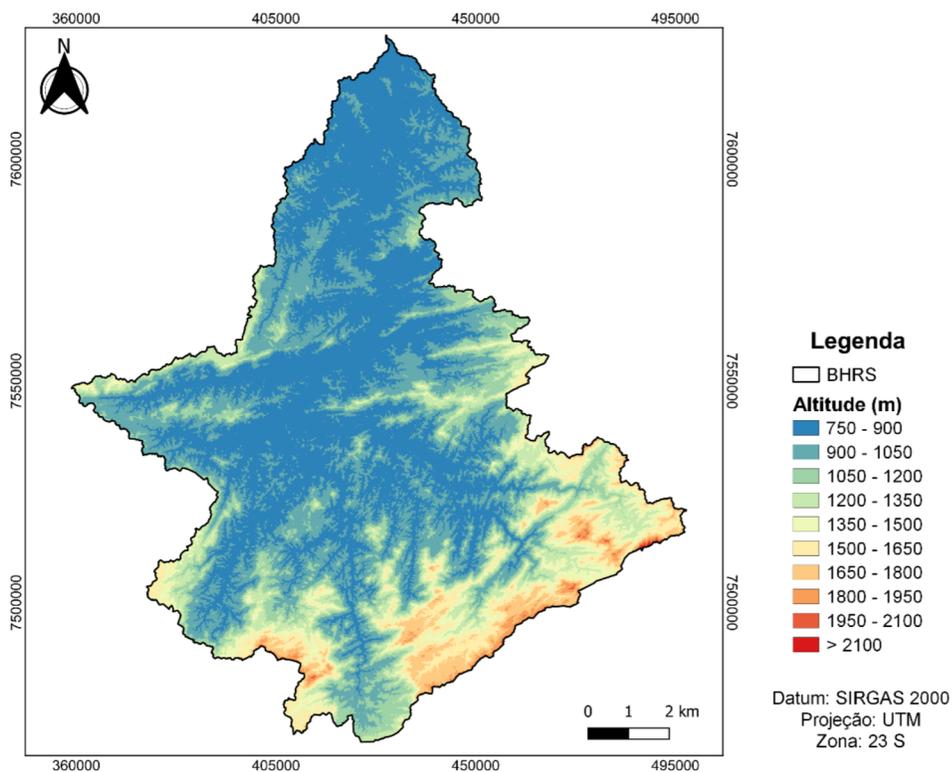


Figura 2 – Mapa hipsométrico da BHRS

A BHRS é dividida em três trechos: Alto Sapucaí, Médio Sapucaí e Baixo Sapucaí; o Alto Sapucaí compreende 21 municípios e apresenta uma área de 3.924 km², que vai desde a nascente em Campos do Jordão até Wenceslau Brás, o Médio Sapucaí também compreende 21 municípios e possui uma área de 3.841 km², que se estende desde Wenceslau Brás até Pouso Alegre, já o Baixo Sapucaí compreende 9 municípios e tem uma área de 1.700 km², que vai de Pouso Alegre até a sua foz, onde está a represa de Furnas (COPASA, 2010).

De todo o território da BHRS, 97% está inserido no bioma Mata Atlântica, e 3% no bioma Cerrado. Com relação a Mata Atlântica, há uma diversidade de solos e ecossistemas florestais, já o Cerrado é composto por vegetação rasteira, arbustiva e arbórea (TORRES *et al.*, 2020). O trecho do Alto Sapucaí é marcado por uma maior conservação da vegetação ciliar em relação aos trechos Médio e Baixo Sapucaí, onde apresentam os maiores impactos na vegetação. Nesses trechos, pastagens e culturas ocupam as margens de rios e várzeas, modificando a vegetação ciliar e a dinâmica da várzea (COPASA, 2010).

No trecho do Alto Sapucaí é onde encontra-se a maior declividade de toda a bacia, sendo de 15 m km^{-1} , causando uma alta velocidade de escoamento. Deste modo, a alta variação de declividade desde a nascente até as cidades do sul de MG, tais como: Itajubá, Piranguinho, Santa Rita do Sapucaí e Pouso Alegre, faz com que as mesmas se tornem suscetíveis a frequentes inundações nas vegetações ciliares e nas planícies aluviais adjacentes ao rio (COPASA, 2010; SILVA *et al.*, 2011; TEODORO *et al.*, 2020).

3.2 Dados de estações pluviométricas em solo

Para validar as estimativas de precipitação por satélite, foram utilizados dados de estações pluviométricas disponibilizados pela ANA, através do portal HIDROWEB (<http://www.snirh.gov.br/hidroweb/serieshistoricas>). Esses dados são submetidos ao controle de qualidade da ANA antes de serem disponibilizados, a fim de evitar dados errôneos (TEODORO *et al.*, 2020). A justificativa para a escolha desses dados se deu pelo fato destes apresentarem uma série histórica maior e com menos falhas do que outras estações provenientes de outros bancos de dados.

Foram utilizados dados diários para o período de abril de 2014 a dezembro de 2019, onde a precipitação acumulada do dia corresponde a chuva das 07 h do dia anterior até às 07 h do dia atual (10 UTC às 10 UTC; ANA, 2014). Foram selecionadas 44 estações pluviométricas dentro e no entorno da BHRS (Tabela 1 e Figura 3). Os dias em que as estações pluviométricas não registraram valores de precipitação (iguais a -1) foram removidos da série histórica, a fim de se realizar uma comparação correta entre os dados.

Tabela 1 – Informações das estações pluviométricas da ANA

Código da estação	Município	Latitude	Longitude	Altitude
2145001	Conceição do Rio Verde	-21.88	-45.07	858
2145003	Três Corações	-21.72	-45.26	845
2145008	Cambuquira	-21.87	-45.25	856
2145009	Campanha (Usina do Chicão)	-21.91	-45.47	1032
2145017	Monsenhor Paulo	-21.76	-45.53	864
2145020	Três Corações (Chácara Santana)	-21.67	-45.25	902
2145024	Campanha (Palmela dos Coelho)	-21.78	-45.44	848
2145042	Alfenas	-21.45	-45.94	887
2145044	Carmo da Cachoeira	-21.46	-45.22	932
2146029	Poço Fundo (Cachoeira)	-21.79	-46.12	820
2146084	Poço Fundo (PCH Barramento)	-21.80	-46.13	1153
2245000	Santa Rita do Sapucaí	-22.25	-45.70	866
2245010	Campos do Jordão (Fazenda da Guarda)	-22.68	-45.48	1506
2245011	São Bento do Sapucaí	-22.68	-45.73	981
2245018	Campos do Jordão (Vila Capivari)	-22.71	-45.56	1617
2245020	Lorena	-22.73	-45.08	541
2245064	Delfim Moreira	-22.50	-45.28	1328
2245065	Cristina	-22.21	-45.26	1002
2245066	Conceição dos Ouros	-22.41	-45.79	861
2245070	Brazópolis	-22.47	-45.62	869
2245074	Careaçu	-22.05	-45.69	873
2245077	Pouso Alegre	-22.24	-45.95	823
2245080	Virgínia	-22.33	-45.09	936
2245083	Itajubá	-22.37	-45.44	851
2245084	Consolação	-22.56	-45.88	893
2245085	Silvianópolis (Vargem do Cervo)	-22.13	-45.91	858
2245086	Pouso Alegre (Ponte do Rodrigues)	-22.35	-45.85	824
2245087	Delfim Moreira (Bairro Santa Cruz)	-22.40	-45.21	1429
2245088	Maria da Fé	-22.31	-45.37	1277
2245089	Silvianópolis	-22.03	-45.83	871
2245090	Conceição das Pedras	-22.16	-45.45	1087
2245104	Sapucaí-Mirim	-22.74	-45.74	890
2245191	Cachoeira Paulista	-22.63	-45.03	564
2246047	Santa Rita de Caldas	-22.02	-46.30	1127
2246050	Cambuí	-22.60	-46.03	894
2246056	Inconfidentes	-22.32	-46.32	856
2246057	Camanducaia	-22.76	-46.14	1041
2246127	Borda da Mata	-22.27	-46.16	905
2246167	Extrema (Nascente Principal)	-22.88	-46.24	1149
2246168	Extrema (Sítio São José)	-22.86	-46.24	998
2246169	Extrema (Sítio Canto da Siriema)	-22.86	-46.24	998
2246170	Extrema (Sítio Bela Vista)	-22.84	-46.24	1074
2246171	Extrema (Recanto do Ratinho)	-22.83	-46.22	983
2246175	Extrema (Foz Ribeirão das Posses)	-22.83	-46.23	985

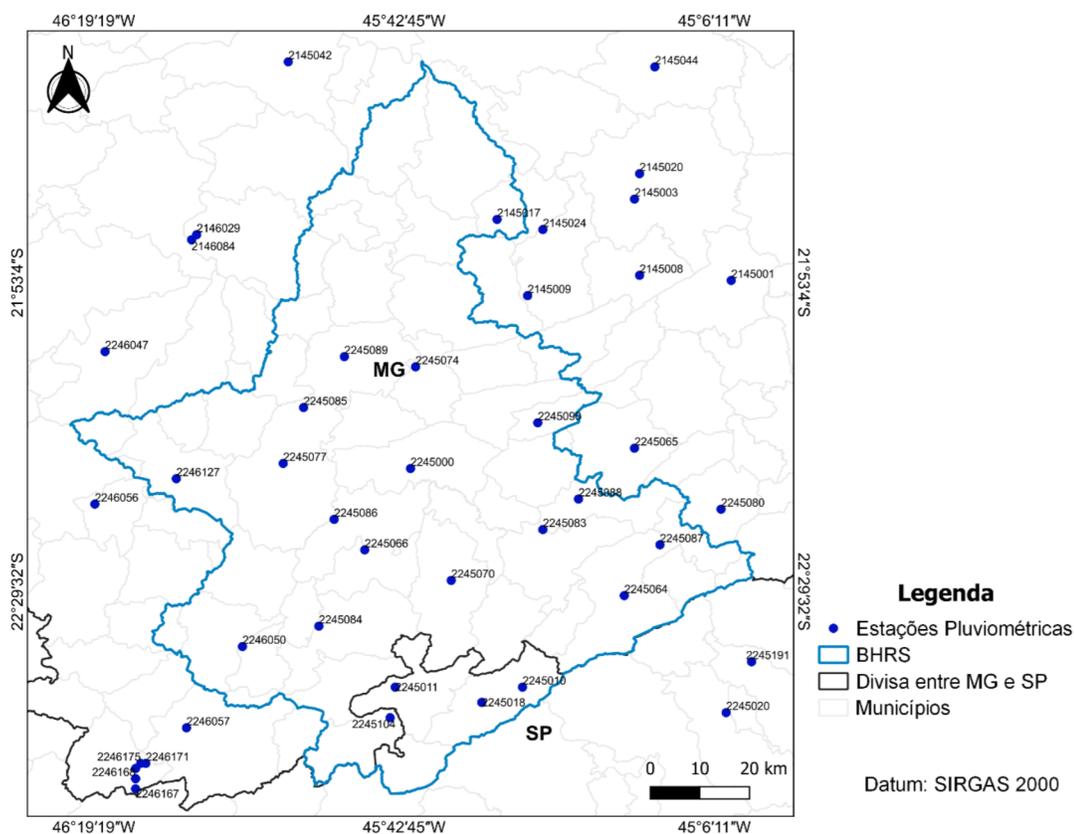


Figura 3 – Mapa da localização das estações pluviométricas utilizadas no estudo

3.3 Dados GPM-IMERG

Para este estudo, foram utilizadas as estimativas da precipitação de nível 3 do GPM, selecionando o produto *Final Run* da versão 06, para o período de abril de 2014 a dezembro de 2019. Esses dados estão disponíveis através do sítio eletrônico da NASA

(https://disc.gsfc.nasa.gov/datasets/GPM_3IMERGHH_06/summary?keywords=%22IMERG%20final%22). Os dados são disponibilizados a cada 30 minutos e possuem resolução espacial de 0,1° (HUFFMAN *et al.*, 2015). Preferiu-se trabalhar com dados horários ao invés de diários devido ao acumulado do satélite ser das 12 UTC do dia anterior às 12 UTC do dia atual (9 h local), o que acaba gerando uma defasagem de duas horas com os dados das estações pluviométricas da ANA. Deste modo, gerou-se o acumulado diário da estimativa do satélite para o horário das 10 às 10 UTC, coincidindo então com o horário da estação, a fim de realizar a comparação e a validação entre si.

3.4 Métodos

A Figura 4 resume em um fluxograma as etapas realizadas para o desenvolvimento do projeto.

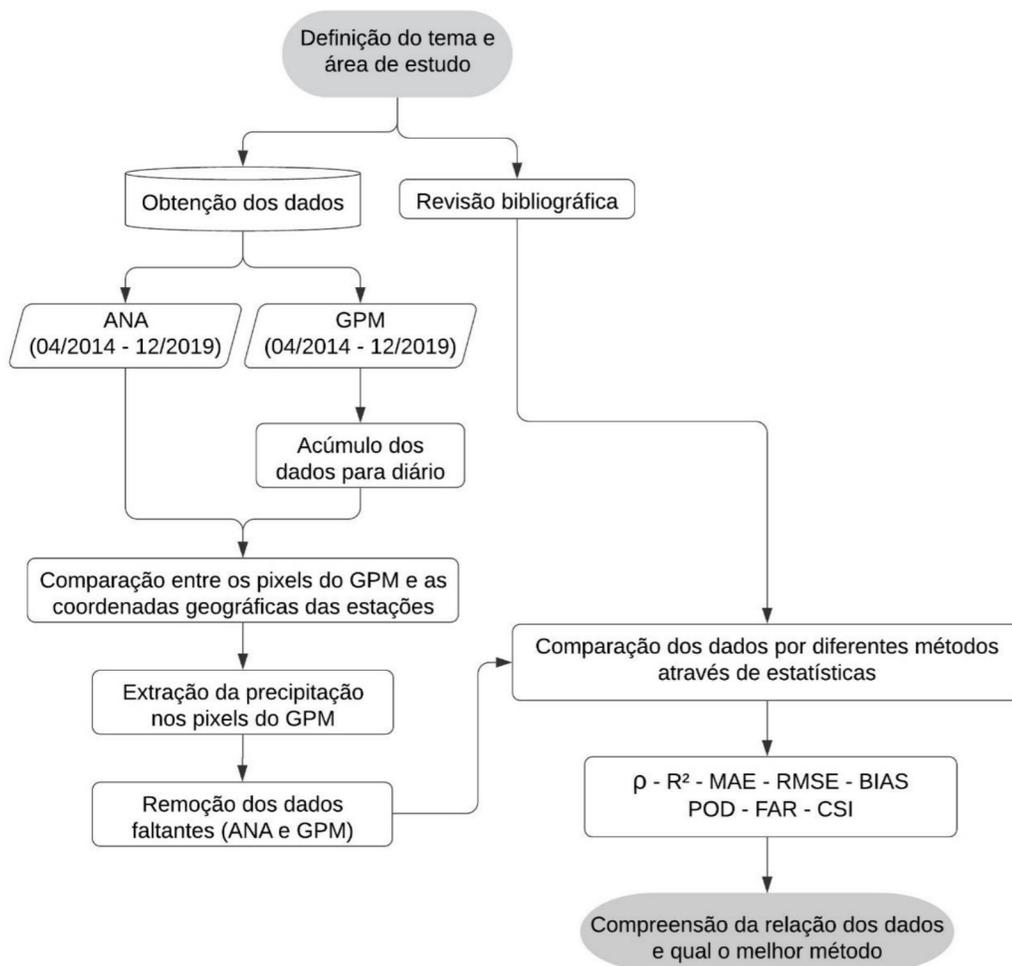


Figura 4 – Fluxograma da metodologia utilizada no estudo

Primeiramente, foi realizado um extenso levantamento bibliográfico, a fim de compreender e conhecer estudos similares já existentes na literatura, como forma de auxiliar no desenvolvimento metodológico do trabalho.

Foi realizado também a obtenção dos dados das estações pluviométricas da ANA e do satélite GPM. Foram selecionadas estações pluviométricas disponíveis entre as coordenadas geográficas: -46.44, -44.95, -22.93 e -21.39, que continham dados entre o período de abril de 2014 e dezembro de 2019, com menos de 50% de dados faltantes. Os dias sem registro de precipitação foram removidos da série. Com isso, foram selecionadas 44 estações meteorológicas. Os dados do GPM foram

obtidos para toda a região do Brasil, porém foram recortados para a mesma área definida. Como optou-se por trabalhar com dados horários (30 minutos), foram necessários alguns ajustes, tais como o cálculo do acumulado diário (10 UTC do dia anterior às 10 UTC do dia) e a transformação do dado de mm hora^{-1} para mm dia^{-1} .

Após os ajustes dos dados, o primeiro método selecionado para realizar a comparação entre as duas séries de dados foi o ponto a pixel – onde os dados foram comparados entre si, sem passar por nenhum processamento, assim como descrito por Quedi, Campos e Fan (2018), para a Bacia Hidrográfica do Rio São Francisco; Soares, Paz e Picilli (2016), para o estado da Paraíba e Medeiros-Feitosa e Oliveira (2020), para o estado do Ceará. Para essa metodologia, realizou-se comparações entre os dados para as estações de verão e inverno, além da série completa, a fim de compreender a relação desses dados em meses mais chuvosos e mais secos. Neste caso, extraiu-se o valor da precipitação estimada pelo GPM do centro do pixel mais próximo da estação meteorológica. Quando coincidia de haver mais de uma estação da ANA para o mesmo pixel do satélite, realizou-se uma média entre os valores registrados nessas estações (Tabela 2 e Tabela 3).

Tabela 2 – Média 1 entre as estações de pixel coincidente

Média 1				
Código da estação	Município	Latitude	Longitude	Altitude
2146029	Poço Fundo (Cachoeira)	-21.79	-46.12	820
2146084	Poço Fundo (PCH Barramento)	-21.80	-46.13	1153

Tabela 3 – Média 2 entre as estações de pixel coincidente

Média 2				
Código da estação	Município	Latitude	Longitude	Altitude
2246167	Extrema (Nascente Principal)	-22.88	-46.24	1149
2246168	Extrema (Sítio São José)	-22.86	-46.24	998
2246169	Extrema (Sítio Canto da Siriema)	-22.86	-46.24	998
2246170	Extrema (Sítio Bela Vista)	-22.84	-46.24	1074
2246171	Extrema (Recanto do Ratinho)	-22.83	-46.22	983
2246175	Extrema (Foz Ribeirão das Posses)	-22.83	-46.23	985

Para avaliar o desempenho dos dados do GPM em relação aos registrados nas estações da ANA, para a série completa, verão e inverno, foram utilizadas algumas métricas estatísticas. Essas estatísticas foram selecionadas com finalidade de mensurar a performance e a capacidade de detecção de ocorrências de eventos de

precipitação. As estatísticas de performance utilizadas foram: Coeficiente de Correlação de Pearson (ρ), Coeficiente de Determinação (R^2), Raiz do Erro Médio Quadrático (RMSE), Erro Médio Absoluto (MAE) e BIAS (Quadro 1). Calculou-se também as estatísticas de contingência, para a série completa, sendo elas: Probabilidade de Detecção (POD), Taxa de Alarme Falso (FAR) e Índice de Sucesso Crítico (CSI; Quadro 2). Essas estatísticas são calculadas utilizando uma técnica composta por uma tabela de contingência (Tabela 4) que indica o potencial do GPM em detectar eventos de precipitação com diferentes intensidades. As categorias de intensidade de precipitação utilizadas no cálculo dessas estatísticas foram retiradas do trabalho de He *et al.* (2017), onde os autores classificaram a precipitação em quatro categorias, com seis classificações, sendo elas: chuva leve (definido entre 0 e 1 mm dia⁻¹), chuva moderada (definido entre 1 e 5 mm dia⁻¹ e entre 5 e 10 mm dia⁻¹), chuva forte (definido entre 10 e 50 mm dia⁻¹ e entre 50 e 100 mm dia⁻¹) e extremos de chuva forte (> 100 mm dia⁻¹).

Tabela 4 – Variáveis apresentadas nas estatísticas de contingência

TABELA DE CONTINGÊNCIA		
ESTIMATIVA (GPM)	OBSERVAÇÃO (ANA)	
	Chuva	Não chuva
Chuva	a	b
Não chuva	c	d

Na tabela de contingência, a letra *a* representa os eventos de precipitação que ocorreram nos pluviômetros e o satélite registrou; a letra *b* representa os eventos de precipitação que o satélite registrou, porém não ocorreram nos pluviômetros; a letra *c* representa os eventos de precipitação que ocorreram nos pluviômetros e o satélite não registrou; e a letra *d* representa a não ocorrência de precipitação nos pluviômetros e no satélite, simultaneamente.

O segundo método escolhido para a comparação dos conjuntos de dados, foi o pixel a ponto – onde os dados do GPM passaram por um processo de remoção de viés e foram comparados com os dados da estação, assim como no trabalho de Braga, Cataldi e Oliveira (2009). Para essa metodologia, e todas as posteriores, foram realizadas comparações apenas para a série completa, pois através da primeira metodologia já foi possível observar o comportamento do satélite no verão e inverno.

Nesta etapa, primeiramente construiu-se as curvas de permanência – modelo gráfico bidimensional que apresenta a frequência em que uma variável, com determinado valor de referência, permanece igual ou superior a esse valor de referência, ou seja, a porcentagem de tempo em que a variável é superada ou igualada ao valor de referência de toda a série histórica (CRUZ; TUCCI, 2008; PETRUCCI, 2018); através dos intervalos de precipitação encontrados para cada porcentagem (0 a 100, com variação de 1). Após a obtenção desses intervalos, realizou-se a remoção de viés dos dados do GPM baseado nos dados das estações da ANA e do método IQD. A partir dessa nova série de dados do GPM, foi feita uma comparação através das estatísticas apresentadas no Quadro 1, e também foram geradas novas curvas de permanência.

O terceiro método foi o pixel a pixel – dados das estações da ANA foram interpolados (IQD) para a mesma grade do GPM, ou seja, a grade interpolada coincide com o centro do pixel do GPM, conforme realizado também por Melo *et al.* (2015), Gadêlha (2018) e Medeiros-Feitosa e Oliveira (2020). Com o resultado dessa interpolação, todos os centros dos pixels do GPM (área: -46.44, -44.95, -22.93 e -21.39) possuíam uma série de dados da ANA correspondente. Sendo assim, realizou-se uma comparação estatística (Quadro 1) entre essas séries de dados.

No quarto e último método, foram calculadas médias nas áreas a partir dos dados obtidos no método pixel a pixel, como feito no trabalho de Gadêlha (2018). Para esse passo, dividiu-se a BHRS em subáreas, tais como: Alto, Médio e Baixo Sapucaí, e a partir disso, construiu-se três quadrados referentes a essas subáreas. Para cada subárea foi feito uma média entre os valores de todos os dados da ANA e do GPM, e em seguida, realizou-se os cálculos de todas as estatísticas (Quadro 1).

A aplicação dessas estatísticas para os quatro métodos considerados no presente estudo, possibilitou obter uma melhor análise e compreensão da relação entre os dois conjuntos de dados de precipitação, e também a identificação do método que apresentasse o melhor desempenho em termos de estatística.

Quadro 1 – Métricas estatísticas utilizadas na comparação entre os dados

ESTATÍSTICA	EQUAÇÃO
<p>Correlação de Pearson (ρ): identifica o grau de correlação entre os dados da ANA e do GPM, e pode variar de -1 a 1. Quando a correlação é -1 ou 1 pode-se dizer que é uma correlação perfeita, enquanto que uma correlação 0 indica que não há nenhuma relação linear entre as variáveis (FIGUEIREDO FILHO; SILVA JÚNIOR, 2009). De acordo com a definição de Hinkle <i>et al.</i> (2003), conforme citado por Torres <i>et al.</i> (2020, p. 383), os intervalos de correlação podem ser definidos como: de 0 a 0,3 (0 a -0,3) a correlação é muito fraca; de 0,3 a 0,5 (-0,3 a -0,5) a correlação é fraca; de 0,5 a 0,7 (-0,5 a -0,7) a correlação é moderada; de 0,7 a 0,9 (-0,7 a -0,9) a correlação é alta e de 0,9 a 1 (-0,9 a -1) a correlação é muito alta.</p>	$\rho = \frac{\sum_{t=1}^n [(ANA_t - \overline{ANA})(GPM_t - \overline{GPM})]^2}{\sqrt{\sum_{t=1}^n [ANA_t - \overline{ANA}]^2} \sqrt{\sum_{t=1}^n [GPM_t - \overline{GPM}]^2}}$
<p>Coefficiente de Determinação (R^2): também utilizado para mensurar o grau de correlação entre variáveis, isto é, é uma medida do quão bem a estimativa do GPM se ajusta aos dados da ANA (MONTGOMERY; JENNINGS; KULAHCI, 2008). Essa estatística é definida como a Correlação de Pearson elevado ao quadrado (GUIMARÃES, 2020). Os valores variam de 0 a 1 e quanto mais próximo de 1, melhor é a qualidade de ajuste do GPM em relação aos dados da ANA.</p>	$R^2 = \frac{[\sum_{t=1}^n (ANA_t - \overline{ANA})(GPM_t - \overline{GPM})]^2}{\sum_{t=1}^n [ANA_t - \overline{ANA}]^2 \sum_{t=1}^n [GPM_t - \overline{GPM}]^2}$
<p>Erro Absoluto Médio (MAE): é uma medida de erro utilizada para representar a diferença absoluta média entre os valores estimados pelo GPM e os observados em solo, onde o mesmo é pouco sensível a valores extremos (MONTGOMERY; JENNINGS; KULAHCI, 2008; SANTOS <i>et al.</i>, 2011). O melhor valor do MAE é 0 ou próximo disso, podendo ser consideradas como previsões perfeitas, valores altos dessa estatística significa bastante discrepância entre os dados (WILKS, 2011).</p>	$MAE = \frac{1}{n} \sum_{t=1}^n GPM_t - ANA_t $
<p>Raiz do Erro Médio Quadrático (RMSE): é uma medida da variabilidade no erro entre o GPM e a ANA (MONTGOMERY; JENNINGS; KULAHCI, 2008). Essa medida é similar ao MAE, porém é utilizado a função quadratura e não valor absoluto. Como essa estatística é calculada pela quadratura do erro, é mais sensível a erros do que o MAE (WILKS, 2011). Quanto menor o valor, mais próximos estarão os dados do GPM e da ANA.</p>	$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n [GPM_t - ANA_t]^2}$
<p>BIAS: é uma estimativa do valor esperado do desvio entre os dados do GPM e da ANA, portanto, expressa o viés/bias do GPM. Quanto mais próximo de 0, melhor é o bias (MONTGOMERY; JENNINGS; KULAHCI, 2008; WILKS, 2011). Essa estatística revela a tendência da estimativa do GPM em subestimar ou superestimar os valores observados em solo (VIANA; FERREIRA; CONFORTE, 2010).</p>	$BIAS = \frac{1}{n} \sum_{t=1}^n (GPM_t - ANA_t)$

Quadro 2 – Métricas estatísticas de contingência utilizadas na comparação entre os dados

ESTATÍSTICAS DE CONTINGÊNCIA	EQUAÇÃO
<p>Probabilidade de Detecção (POD): demonstra a proporção de ocorrências de eventos de precipitação que foram detectados corretamente (WILKS, 2011). Quanto mais próximo de 1, melhor a detecção. De acordo com Gadêlha (2018), esse índice é sensível aos sucessos porém ignora os falsos alarmes, sendo assim, é importante se calcular também a FAR.</p>	$POD = \frac{a}{a + c}$
<p>Taxa de Falso Alarme (FAR): considerada a fração de ocasiões em que o GPM detectou eventos de precipitação, porém não ocorreu na estação. O melhor valor dessa estatística é 0 e o pior é 1 (WILKS, 2011). Segundo Gadêlha (2018), esse índice é sensível aos falsos alarmes porém ignora as falhas.</p>	$FAR = \frac{b}{a + b}$
<p>Índice de Sucesso Crítico (CSI): Considerada a fração de eventos de precipitação do GPM que foram corretamente detectados, desconsiderando as detecções falsas. O pior valor de CSI é 0 e a melhor é 1 (WILKS, 2011). Esse índice é sensível a acertos, penaliza os falsos alarmes e as falhas (GADÊLHA, 2018).</p>	$CSI = \frac{a}{a + b + c}$

4 RESULTADOS E DISCUSSÕES

4.1 Caracterização da Precipitação na BHRS

Para obter uma maior compreensão e conhecimento de como foi o regime de precipitação por sub-bacia da BHRS para o período estudado, utilizou-se os dados de precipitação da ANA obtidos na metodologia pixel a pixel. Para a confecção da Figura 5, acumulou-se os dados diários para mensais, e após isso realizou-se médias para cada mês do ano para cada sub-bacia. Já na Figura 6, foi realizado o acumulado anual para cada sub-bacia.

Através da Figura 5, observa-se que os maiores acumulados mensais de precipitação ocorrem entre novembro e março, alcançando 225 mm mês^{-1} no Médio Sapucaí em janeiro, e os menores no inverno (junho-agosto), chegando a 12 mm mês^{-1} no Baixo Sapucaí em julho. O Médio Sapucaí é responsável pelo maior acumulado em quase todos os meses do ano, exceto nos meses de inverno e em novembro. A segunda sub-bacia com maiores acumulados é o Alto Sapucaí e por ultimo o Baixo Sapucaí.

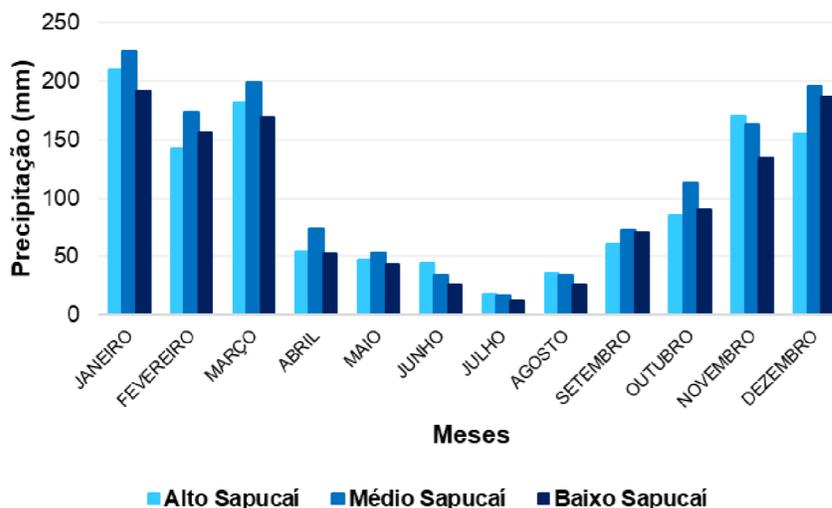


Figura 5 – Média mensal de precipitação na BHRS

Os acumulados anuais de precipitação para a bacia encontram-se na Figura 6. Os valores anuais para 2014 ficaram bem abaixo do restante pois os dados são

acumulados a partir de abril, perdendo-se três meses de informação. No entanto, Silva *et al.* (2020) encontrou anomalias negativas de precipitação para janeiro dos anos entre 2014 a 2019, exceto para 2016 – anomalia positiva; indicando que choveu abaixo da média climatológica em janeiro desses anos. De acordo com a Figura 5, janeiro é o mês com os maiores acumulados do ano, sendo assim, afeta diretamente os acumulados anuais. Analisando a Figura 6, observa-se os maiores acumulados das três sub-bacias (Alto: 1405 mm ano⁻¹, Médio: 1525 mm ano⁻¹ e Baixo: 1352 mm ano⁻¹) para o ano de 2016 – anomalia positiva de chuva em janeiro. Em todos os anos, o Médio Sapucaí registrou os maiores acumulados da bacia. Entre 2016 e 2018 o Baixo Sapucaí registrou os menores acumulados, nos outros anos, os valores ficaram bem próximos do Alto Sapucaí. No geral, os acumulados variaram de 1100 a 1400 mm ano⁻¹ no Alto Sapucaí, de 1200 a 1500 mm ano⁻¹ no Médio Sapucaí e de 1000 a 1300 mm ano⁻¹ no Baixo Sapucaí.

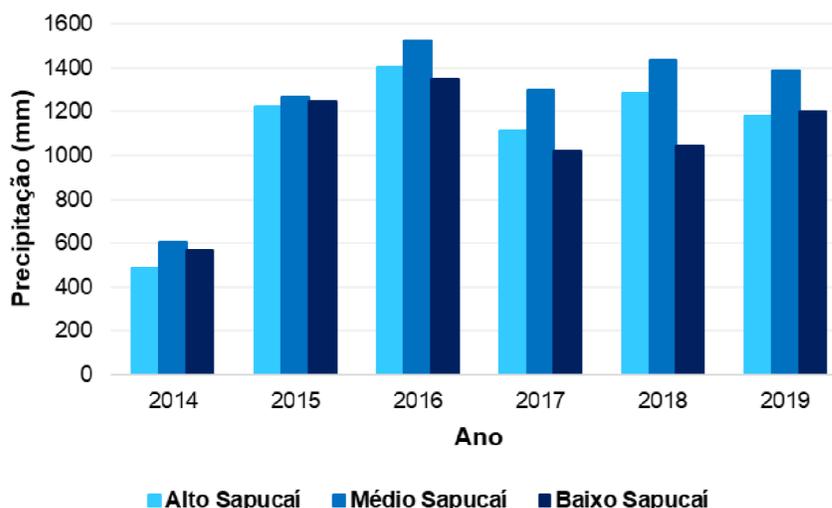


Figura 6 – Acumulado anual de precipitação na BHRS

4.2 Análise Ponto a Pixel

4.2.1 Análise da série completa (04/2014 a 12/2019)

Para a análise de todo o período de dados, exceto os dias com dados faltantes na estação pluviométrica, foram calculadas as estatísticas apresentadas na seção anterior. O contraste entre os dados do GPM e da ANA serão explicados por meio dessa análise. A Figura 7 apresenta gráficos de dispersão com os valores obtidos nas

estatísticas para cada ponto da estação e *pixel* do satélite e a Figura 8 apresenta esses mesmos valores, porém indicando a localização de cada estação no mapa. Mais detalhes desses valores estão destacados na Tabela 5. Através da Figura 7, nota-se que a maioria das estações se localizavam entre 800 e 1000 m de altitude.

Percebe-se analisando as Figuras 7a e 8a, que representam os valores da Correlação de Pearson, que a maioria dos pontos se encontram no intervalo de 0,5 a 0,8. De acordo com Torres *et al.* (2020), esses resultados indicam correlações moderadas e altas entre os dados. Poucos pontos ficaram abaixo de 0,5 e o menor valor encontrado foi de 0,2 (Tabela 5), indicando correlações muito fracas e correlações fracas. De modo geral, de todas as estações utilizadas, encontrou-se uma correlação moderada (média entre os valores igual a 0,58) entre os dados do GPM e da estação, e ainda nota-se que não foi possível observar um padrão entre os dados e a altitude. Analisando a tabela 5, nota-se que o menor valor de correlação (0,20) ocorreu na cidade de Três Corações (2245020), que está destacada em vermelho, e o maior valor (0,76) nas cidades de Careaçu (2245074) e Pouso Alegre (2245077), destacados em azul. No geral, os valores de correlação foram bons, indicando uma boa estimativa do GPM em relação aos dados da ANA.

As Figuras 7b e 8b apresentam os valores de R^2 , que é uma estatística que indica a proporção em que a quantidade de variância de um conjunto de dado pode explicar o outro (TORRES *et al.*, 2020), e como citado anteriormente no Quadro 1, quanto mais próximo de 1, melhor é a qualidade de ajuste dos dados. Observando as Figuras 7b e 8b, nota-se que a maioria dos pontos ficaram entre 0,30 a 0,60 (30% a 60%), e poucos pontos ficaram abaixo desse valor. De acordo com a Tabela 5, o menor valor de R^2 (0,04 – 4%) também ocorreu para Três Corações (2245020) – destacado em vermelho, e o maior valor (0,58 – 58%) para Careaçu (2245074) – destacado em azul, assim como encontrado na Correlação de Pearson. A média dessa estatística foi de 0,36, o que representa um valor baixo, indicando que o GPM possui uma capacidade explicativa baixa para os dados de precipitação.

Os valores do MAE se encontram nas Figuras 7c e 8c. Como apresentado no Quadro 1, valores do MAE sendo zero indicam que os dados do GPM e da ANA são semelhantes, e quanto mais alto for esse valor, mais discrepâncias existem entre esses dados. De acordo com as Figuras 7c e 8c, nenhum ponto obteve valor do MAE 0 ou próximo disso, os valores variaram entre 2,07 mm dia⁻¹ e 4,76 mm dia⁻¹ (Tabela 5). O menor valor de MAE (2,07 mm dia⁻¹) foi para a cidade de Monsenhor Paulo

(2145017), e está destacado em azul na tabela 5, já o maior valor (4,76 mm dia⁻¹), foi para a cidade de Conceição das Pedras (2245090), destacado em vermelho na Tabela 5. Como nenhum ponto se aproximou de zero, conclui-se que os dados do GPM e da ANA possuem diferenças entre si, especialmente a cidade de Conceição das Pedras, que teve correlação e R² baixos, além de um maior valor do MAE.

Os valores da RMSE são apresentados nas Figuras 7d e 8d. Essa estatística se diferencia do MAE devido a amplificar a relevância das maiores diferenças entre o GPM e a ANA (TORRES *et al.*, 2020). Assim como o MAE, quanto menor e mais próximo de zero for a RMSE, mais semelhante serão os dados do GPM e da ANA. De acordo com a Figura 7d, verifica-se que os valores da RMSE, na maioria dos pontos, ficam entre 5,5 mm dia⁻¹ e 9,0 mm dia⁻¹. Apenas um ponto alcança o valor de 11,0 mm dia⁻¹. O menor valor (5,55 mm dia⁻¹) coincide com a cidade com de menor valor do MAE, Monsenhor Paulo (2145017), que está destacado em azul na Tabela 5. Já o maior valor (10,88 mm dia⁻¹) ocorre na cidade de Conceição das Pedras (2245090) também – destacado de vermelho na Tabela 5. Os valores da RMSE, de modo geral, ficaram distantes de zero, indicando que os dois conjuntos de dados foram discrepantes entre si.

Nas Figuras 7e e 8e encontram-se os valores do BIAS, que é uma estatística, como citado no Quadro 1, que revela a tendência de subestimação (valores negativos) ou superestimação (valores positivos) do GPM em relação a ANA. Quando o valor do BIAS é zero não é possível se chegar a uma conclusão a respeito da existência de viés, ou seja, se possui tendência de subestimar ou superestimar (TORRES *et al.*, 2020). Analisando as Figuras 7e 8e, constata-se que não existe um padrão de subestimação ou superestimação apenas, pois os valores estão bem divididos, sendo que 17 pontos registraram padrão de superestimação e 21 de subestimação. A cidade com valor positivo de BIAS mais baixo e próximo de zero (0,01) foi Borda da Mata (2246127) – destacado em azul na Tabela 5, e a de valor mais alto (2,41) foi São Bento do Sapucaí (2245011) – destacado em vermelho. Já para valores negativos de bias, o valor mais próximo de zero (-0,03) foi para a cidade de Campanha (2145009) e o mais distante (-0,75) foi para Campos do Jordão (2245018). Analisando os resultados obtidos da estatística BIAS, conclui-se que, mesmo sem a existência de um padrão, a maior parte dos dados do GPM, subestimam os dados diários da ANA.

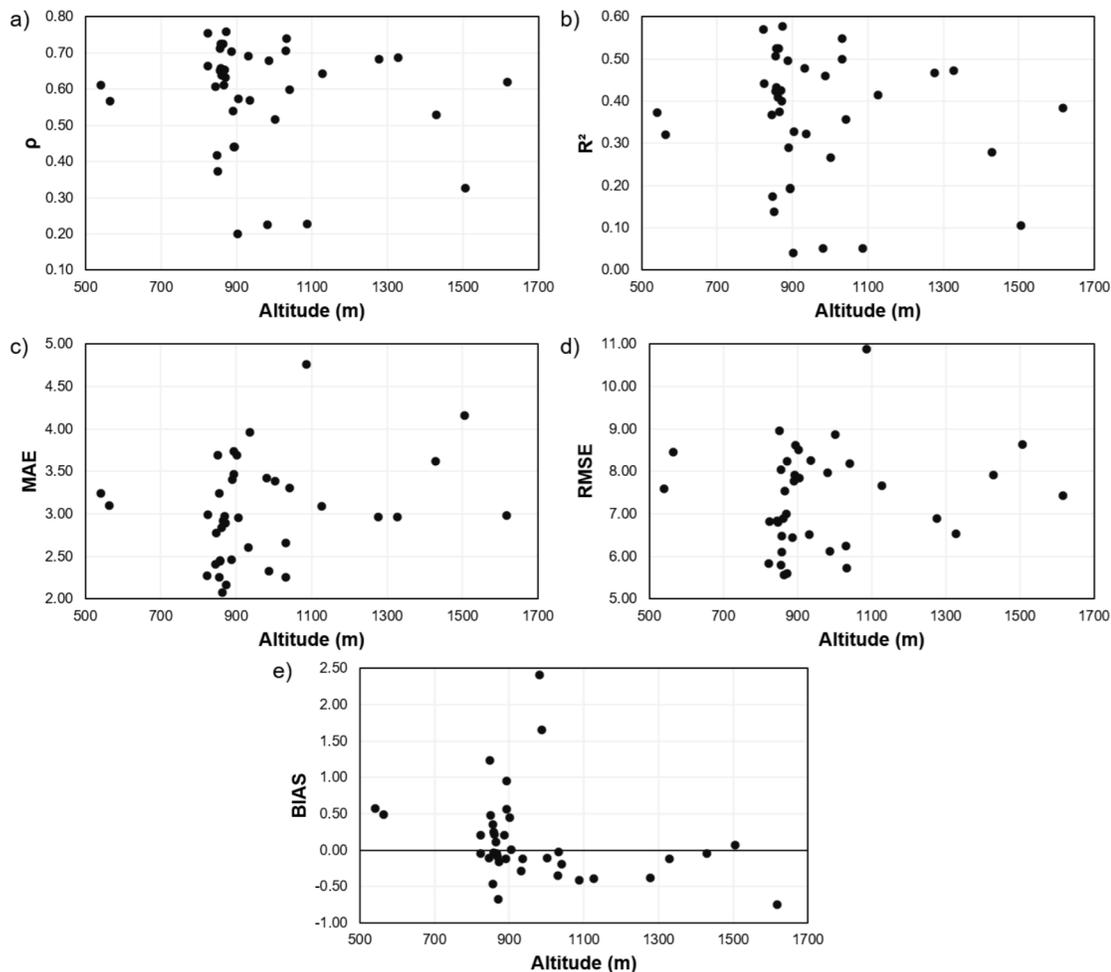


Figura 7 – Métricas estatísticas calculadas para a série completa: a) Correlação de Pearson; b) R^2 ; c) MAE; d) RMSE; e) BIAS

Teodoro *et al.* (2020), que realizou um estudo para a mesma região nos meses de verão, porém utilizando os dados *Early run*, encontraram um valor médio de correlação igual a 0,5, que é um valor bem próximo ao encontrado nesse estudo. Em relação a RMSE, encontraram valores variando de 8,8 mm dia⁻¹ a 15,4 mm dia⁻¹, ou seja, os valores encontrados foram mais altos do que nesse estudo, o que já era esperado, visto que os dados *Early run* são menos processados do que os dados *Final run*. Além disso, Conceição das Pedras obteve um dos valores mais altos da RMSE em ambos os estudos, assim como o BIAS, que apresentou um padrão de subestimação dos dados do GPM nos dois estudos.

Reis, Rennó e Lopes (2017) compararam dados do TRMM e do Hidroestimador com estações pluviométricas em superfície para a região do Alto Sapucaí, e os autores

encontraram que o TRMM possui melhor desempenho do que o Hidroestimador para escalas diárias e mensais, já o Hidroestimador é melhor para escala anual. O TRMM, diferentemente do que foi encontrado nesse estudo, superestimou a precipitação na bacia nas escalas diária, mensal e anual. Já o Hidroestimador subestimou a precipitação, concordando com esse estudo.

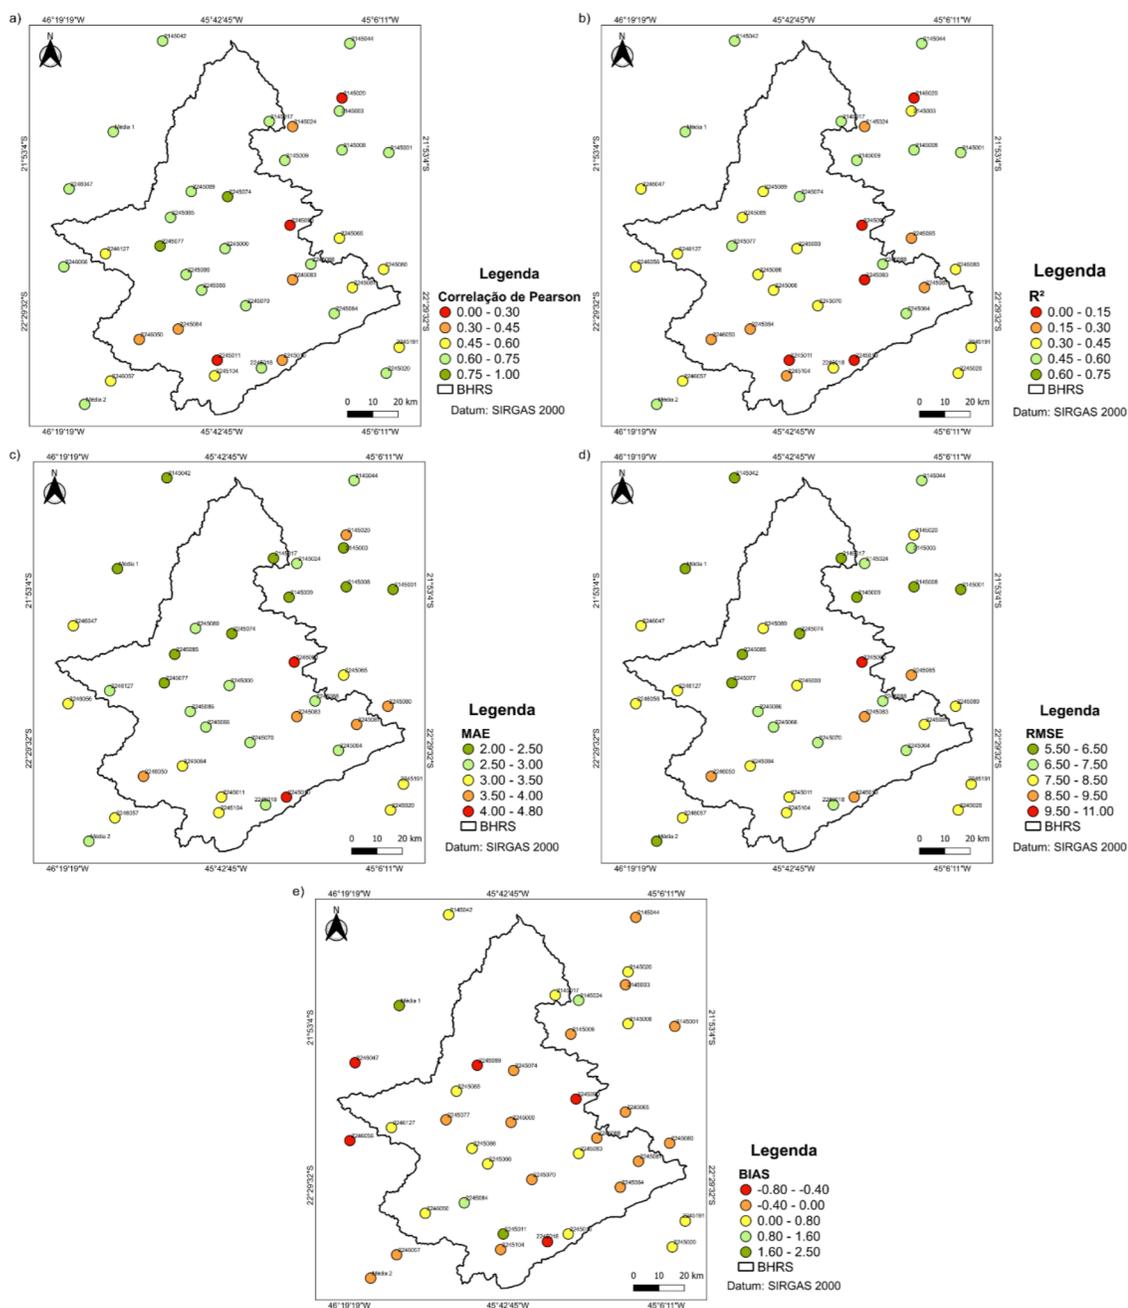


Figura 8 – Mapas das estatísticas calculadas para a série completa: a) Correlação de Pearson; b) R²; c) MAE; d) RMSE; e) BIAS

Tabela 5 – Informações das estações da ANA e valores das estatísticas calculadas para a série completa para avaliar o desempenho da precipitação diária do GPM em relação a ANA. Destacados em vermelho (azul) indicam pior (melhor) desempenho

Estação	Latitude	Longitude	Altitude	ρ	R^2	MAE	RMSE	BIAS
2145001	-21.88	-45.07	858	0.72	0.52	2.45	6.09	-0.04
2145003	-21.72	-45.26	845	0.61	0.37	2.40	6.84	-0.11
2145008	-21.87	-45.25	856	0.71	0.51	2.25	5.79	0.35
2145009	-21.91	-45.47	1032	0.74	0.55	2.25	5.73	-0.03
2145017	-21.76	-45.53	864	0.72	0.52	2.07	5.55	0.11
2145020	-21.67	-45.25	902	0.20	0.04	3.69	8.50	0.45
2145024	-21.78	-45.44	848	0.42	0.17	2.77	6.80	1.24
2145042	-21.45	-45.94	887	0.70	0.50	2.46	6.44	0.21
2145044	-21.46	-45.22	932	0.69	0.48	2.60	6.52	-0.28
2245000	-22.25	-45.70	866	0.61	0.37	2.91	7.55	-0.05
2245010	-22.68	-45.48	1506	0.33	0.11	4.16	8.64	0.07
2245011	-22.68	-45.73	981	0.23	0.05	3.42	7.97	2.41
2245018	-22.71	-45.56	1617	0.62	0.38	2.99	7.42	-0.75
2245020	-22.73	-45.08	541	0.61	0.37	3.24	7.59	0.58
2245064	-22.50	-45.28	1328	0.69	0.47	2.96	6.53	-0.12
2245065	-22.21	-45.26	1002	0.52	0.27	3.39	8.87	-0.11
2245066	-22.41	-45.79	861	0.64	0.41	2.83	6.88	0.22
2245070	-22.47	-45.62	869	0.65	0.43	2.98	6.99	-0.09
2245074	-22.05	-45.69	873	0.76	0.58	2.16	5.60	-0.16
2245077	-22.24	-45.95	823	0.76	0.57	2.27	5.83	-0.05
2245080	-22.33	-45.09	936	0.57	0.32	3.96	8.26	-0.12
2245083	-22.37	-45.44	851	0.37	0.14	3.69	8.95	0.48
2245084	-22.56	-45.88	893	0.44	0.19	3.47	7.92	0.95
2245085	-22.13	-45.91	858	0.66	0.43	2.44	6.48	0.25
2245086	-22.35	-45.85	824	0.66	0.44	2.99	6.82	0.21
2245087	-22.40	-45.21	1429	0.53	0.28	3.62	7.91	-0.05
2245088	-22.31	-45.37	1277	0.68	0.47	2.96	6.89	-0.38
2245089	-22.03	-45.83	871	0.63	0.40	2.89	8.24	-0.67
2245090	-22.16	-45.45	1087	0.23	0.05	4.76	10.88	-0.42
2245104	-22.74	-45.74	890	0.54	0.29	3.40	7.77	-0.12
2245191	-22.63	-45.03	564	0.57	0.32	3.10	8.45	0.49
2246047	-22.02	-46.30	1127	0.64	0.41	3.09	7.66	-0.40
2246050	-22.60	-46.03	894	0.44	0.19	3.73	8.62	0.57
2246056	-22.32	-46.32	856	0.65	0.42	3.24	8.04	-0.47
2246057	-22.76	-46.14	1041	0.60	0.36	3.31	8.18	-0.19
2246127	-22.27	-46.16	905	0.57	0.33	2.96	7.84	0.01
Média 1	-21.80	-46.13	987	0.68	0.46	2.33	6.13	1.65
Média 2	-22.85	-46.24	1031	0.71	0.50	2.66	6.24	-0.35

Os resultados das estatísticas de contingência encontram-se na Figura 9 e na Tabela 6. A POD, como já detalhada no Quadro 2, representa o quão bem o GPM detecta a ocorrência de precipitação, sendo 1 o seu melhor valor. A FAR representa a frequência com que o GPM observou erroneamente ocorrências de precipitação, e o seu melhor valor é 0. Já o CSI representa a fração de precipitação que foi corretamente estimada pelo GPM, com o seu melhor sendo 1. A figura 9 representa os valores dessas estatísticas para os diferentes intervalos de precipitação, no eixo x estão localizados esses intervalos e quantos casos de precipitação ocorreram para cada um deles. Ao analisar a Figura 9 e a Tabela 6, nota-se que o GPM possui um melhor desempenho em estimar a precipitação no intervalo de 0 a 1 mm dia⁻¹, incluindo dias sem precipitação, pois é nesse intervalo que se encontra a maior POD (0,82), a menor FAR (0,07) e o maior CSI (0,78) (Tabela 6). A POD tem uma queda expressiva para os intervalos de 1 a 5 mm dia⁻¹ e de 5 a 10 mm dia⁻¹, enquanto que a FAR tem um aumento para esses mesmos intervalos e o CSI decai juntamente com a POD. Já no intervalo de 10 a 50 mm dia⁻¹, há uma melhora nesses índices, quando comparado aos dois intervalos anteriores, o que indica que o GPM estimou melhor para esse intervalo também. A POD ficou em 0,49, a FAR em 0,50 e o CSI em 0,33 (Tabela 6). Para o intervalo de 50 a 100 mm dia⁻¹, esses índices voltam a ficar ruins e o seu pior valor ocorre para o intervalo acima de 100 mm dia⁻¹, onde a POD é 0, a FAR é 1 e o CSI é 0, ou seja, o GPM apresentou o pior desempenho em estimar a precipitação nesse intervalo. No geral, de acordo com esses índices, o GPM possui uma baixa capacidade para caracterizar eventos de precipitação diária para a região de estudo, coincidindo com o resultado encontrado no trabalho de Teodoro et al. (2020). Gadêlha (2018), que também calculou estatísticas de contingência em seu estudo, encontrou que para as subáreas do sudeste e centro-oeste a taxa de assertividade do GPM foi maior do que para as outras áreas, na escala diária. Reis, Rennó e Lopes (2017) encontraram, através das estatísticas de contingência, que as estimativas por satélites são mais viáveis em estudos de escalas mensais e anuais do que em escalas diárias, podendo justificar os baixos valores estatísticos encontrados nesse estudo, pois é aplicado para escala diária.

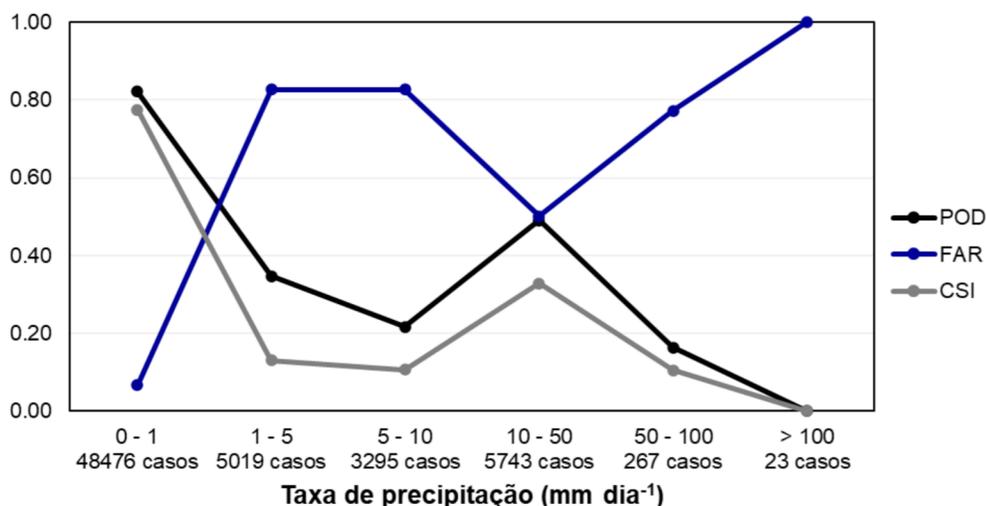


Figura 9 – Métricas estatísticas de contingência para a série completa, considerando diferentes intervalos de precipitação

Tabela 6 – Valores das estatísticas de contingência para cada intervalo de precipitação

ESTATÍSTICAS	INTERVALO DE CHUVA (mm dia ⁻¹)					
	0 - 1	1 - 5	5 - 10	10 - 50	50 - 100	> 100
POD	0,82	0,35	0,22	0,49	0,16	0
FAR	0,07	0,83	0,83	0,50	0,77	1
CSI	0,78	0,13	0,11	0,33	0,11	0

4.2.2 Análise para a estação de verão

Nesta seção serão apresentados os resultados das estatísticas calculadas apenas para os meses de verão (dezembro – janeiro – fevereiro) para todo o período de estudo. Como os resultados anteriores foram para toda a série de dados, não foi possível compreender o comportamento do satélite em relação aos dados em superfície para as estações chuvosas e secas, deste modo, optou-se por calcular as estatísticas tanto para o verão quanto para o inverno, sendo o último, apresentado na próxima seção.

As Figuras 10 e 11 e a Tabela 7 apresentam os resultados das estatísticas para o verão, sendo os melhores valores destacados em azul na tabela e os piores valores em vermelho. As Figuras 10a e 11a mostram os valores de correlação, onde nota-se que a maioria dos pontos ficaram entre 0,40 a 0,75. Analisando a Tabela 7, verifica-se que a menor correlação encontrada foi de 0,14 para a cidade de Três Corações (2145020). Já a maior correlação foi de 0,74 para Monsenhor Paulo (2145017). A

cidade de maior valor coincidiu com a da série completa, porém com valor mais baixo. No geral, a média das correlações para o verão foi de 0,53, indicando, assim como para a série completa, uma correlação moderada entre os dados do GPM e da ANA.

As Figuras 10b e 11b apresentam os valores de R^2 para a região de estudo. Através dessa figura é evidente que os valores dessa estatística variaram entre 0,20 a 0,60 em sua maioria. As cidades com os menores valores de R^2 (0,02) foram Três Corações (2145020) e São Bento do Sapucaí (2245011). A cidade de maior valor de R^2 (0,55), assim como na correlação, foi Monsenhor Paulo (2145017) (Tabela 7). Como os valores dessa estatística foram baixos no geral (média igual a 0,31), bem distantes de 1, pôde-se concluir que o GPM possui uma baixa capacidade explicativa para os dados da ANA.

Os valores do MAE encontram-se nas Figuras 10c e 11c, e nota-se que em nenhum ponto o valor foi zero ou próximo disso. Seus valores variaram entre 4 mm dia⁻¹ e 8 mm dia⁻¹ (Figura 10c). O menor valor do MAE foi de 4,17 mm dia⁻¹ para Monsenhor Paulo (2145017) e o maior valor foi de 7,87 mm dia⁻¹ para Três Corações (2145020) (Tabela 7). Os valores do MAE, no geral, foram mais altos para a estação de verão (média igual a 5,55 mm dia⁻¹) quando comparada com a série completa. Deste modo, nota-se que, assim como para a série completa, os dados do GPM e da ANA possuem discrepâncias entre si e se encontram distantes dos valores perfeitos (zero), sendo esses valores mais expressivos na estação de verão.

Nas Figuras 10d e 11d, se encontram os resultados da RMSE. Essa estatística, no verão, varia entre 7,8 mm dia⁻¹ e 15 mm dia⁻¹. Assim como o MAE, a RMSE atinge valores mais altos se comparado com a série completa. De acordo com a Tabela 7, o valor mais baixo da RMSE (7,97 mm dia⁻¹) foi para Pouso Alegre (2245077). Já o valor mais alto foi para Silvianópolis (2245089), sendo de 14,53 mm dia⁻¹. Diante desses resultados, como os valores da RMSE ficaram distantes de zero e ainda um pouco mais elevado do que para toda a série, concluiu-se que houve discrepâncias entre os dados do GPM e da ANA.

Os resultados do BIAS se encontram nas Figuras 10e e 11e, onde nota-se que, assim como ocorreu para a série completa, não existe um padrão de subestimação ou superestimação. De todos os pontos, 21 sofreram tendência de superestimação, e o restante de subestimação. Quando comparado com a série completa, a quantidade de estações em que o GPM superestimou a precipitação foi maior no verão. O valor do BIAS positivo mais próximo de zero foi de 0,02 para as cidades de Campanha

(2145009) e Sapucaí-Mirim (2245104) e o positivo mais alto foi de 4,38 para São Bento do Sapucaí (2245011). Para os valores negativos do BIAS, o mais próximo de zero foi de -0,06 para Monsenhor Paulo (2145017) e o mais alto foi de -2,14 para Silvianópolis (2245089) (Tabela 7). A cidade com valor mais alto do BIAS positivo coincidiu com a série completa. Diante desses resultados do BIAS, e levando em consideração que atingiram valores mais altos do que para a série completa, verifica-se que a maior parte dos dados do GPM superestimam os dados diários da ANA, diferentemente do que foi encontrado para a série completa.

Como o verão corresponde a estação chuvosa na região do estudo, o satélite teria maior dificuldade em estimar o volume de precipitação corretamente, dessa forma esperava-se que os valores dessas estatísticas não fossem boas, como de fato ocorreu. Os valores encontrados para essas estatísticas foram mais baixos se comparados com os valores para a série completa. Hashemi *et al.* (2017), que realizaram comparações estatísticas para todas as estações do ano para a região do CONUS, encontraram que os piores resultados das estatísticas foram no inverno, período em que ocorre a estação mais úmida em sua região de estudo. Com base nos resultados obtidos, e levando em conta que é no verão que ocorre a estação chuvosa da BHRS, pode se dizer que os piores valores estatísticos também serão encontrados para essa estação.

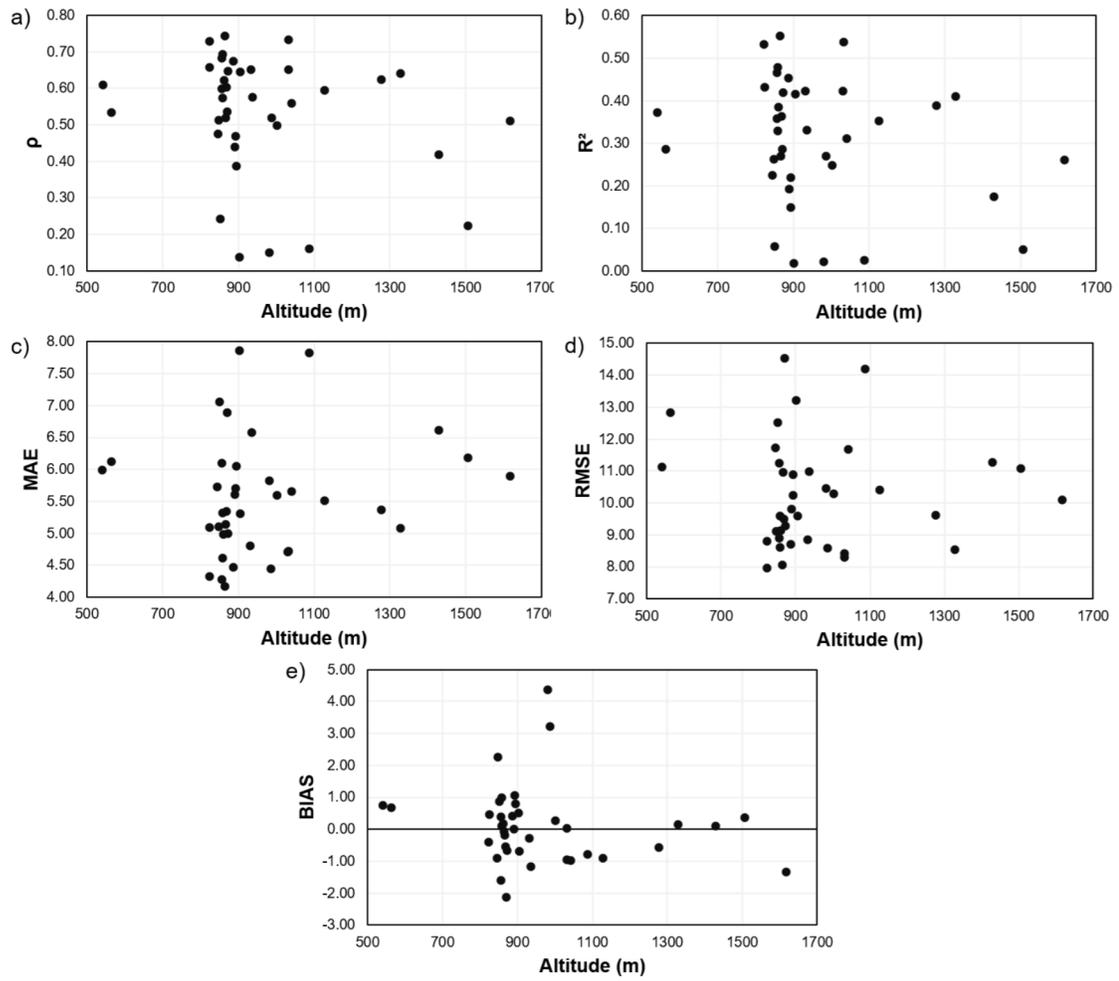


Figura 10 – Métricas estatísticas calculadas para a estação de verão: a) Correlação de Pearson; b) R^2 ; c) MAE; d) RMSE; e) BIAS

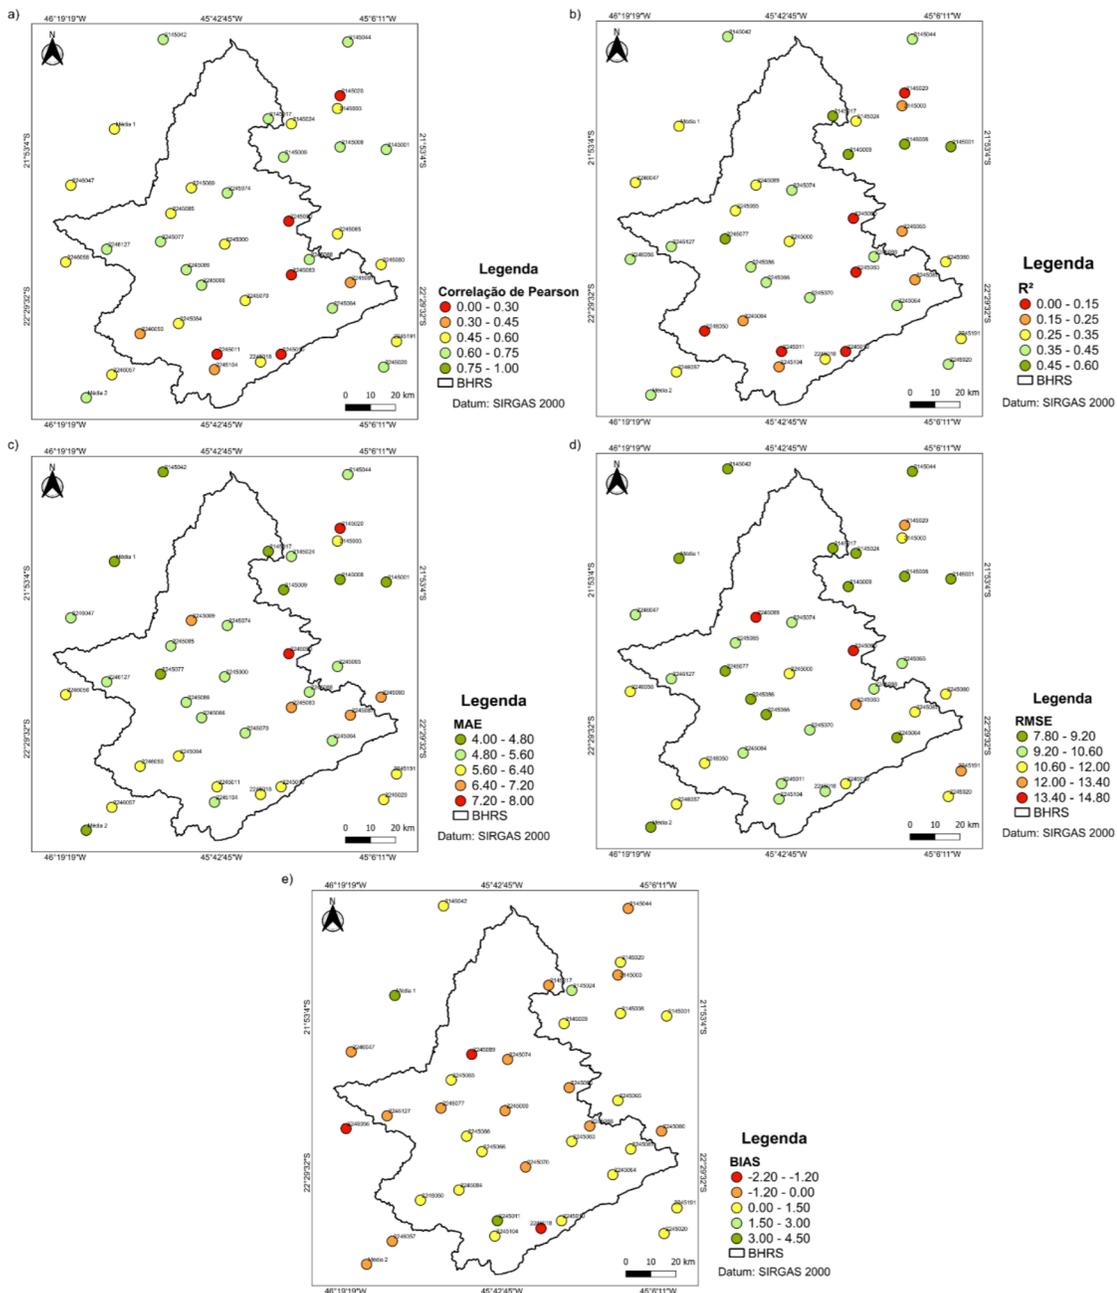


Figura 11 – Mapas das estatísticas calculadas para a estação de verão: a) Correlação de Pearson; b) R²; c) MAE; d) RMSE; e) BIAS

Tabela 7 – Informações das estações da ANA e valores das estatísticas calculadas para o verão para avaliar o desempenho da precipitação diária do GPM em relação a ANA. Destacados em vermelho (azul) indicam pior (melhor) desempenho

Estação	Latitude	Longitude	Altitude	ρ	R^2	MAE	RMSE	BIAS
2145001	-21.88	-45.07	858	0.69	0.48	4.61	8.61	0.09
2145003	-21.72	-45.26	845	0.47	0.23	5.72	11.74	-0.91
2145008	-21.87	-45.25	856	0.68	0.47	4.28	8.90	0.38
2145009	-21.91	-45.47	1032	0.73	0.54	4.72	8.29	0.02
2145017	-21.76	-45.53	864	0.74	0.55	4.17	8.06	-0.06
2145020	-21.67	-45.25	902	0.14	0.02	7.87	13.21	0.51
2145024	-21.78	-45.44	848	0.51	0.26	5.10	9.12	2.27
2145042	-21.45	-45.94	887	0.67	0.45	4.47	8.71	0.40
2145044	-21.46	-45.22	932	0.65	0.42	4.81	8.85	-0.27
2245000	-22.25	-45.70	866	0.52	0.27	5.14	10.95	-0.18
2245010	-22.68	-45.48	1506	0.22	0.05	6.19	11.08	0.36
2245011	-22.68	-45.73	981	0.15	0.02	5.83	10.47	4.38
2245018	-22.71	-45.56	1617	0.51	0.26	5.89	10.10	-1.33
2245020	-22.73	-45.08	541	0.61	0.37	5.99	11.12	0.75
2245064	-22.50	-45.28	1328	0.64	0.41	5.07	8.53	0.15
2245065	-22.21	-45.26	1002	0.50	0.25	5.60	10.28	0.26
2245066	-22.41	-45.79	861	0.62	0.39	4.98	9.15	0.17
2245070	-22.47	-45.62	869	0.60	0.36	5.34	9.49	-0.55
2245074	-22.05	-45.69	873	0.65	0.42	4.99	9.29	-0.66
2245077	-22.24	-45.95	823	0.73	0.53	4.33	7.97	-0.41
2245080	-22.33	-45.09	936	0.58	0.33	6.58	10.97	-1.18
2245083	-22.37	-45.44	851	0.24	0.06	7.06	12.53	0.87
2245084	-22.56	-45.88	893	0.47	0.22	5.70	10.25	1.07
2245085	-22.13	-45.91	858	0.57	0.33	5.32	9.59	0.98
2245086	-22.35	-45.85	824	0.66	0.43	5.09	8.79	0.45
2245087	-22.40	-45.21	1429	0.42	0.17	6.62	11.27	0.09
2245088	-22.31	-45.37	1277	0.62	0.39	5.36	9.62	-0.58
2245089	-22.03	-45.83	871	0.54	0.29	6.89	14.53	-2.14
2245090	-22.16	-45.45	1087	0.16	0.03	7.83	14.19	-0.78
2245104	-22.74	-45.74	890	0.44	0.19	5.60	9.80	0.02
2245191	-22.63	-45.03	564	0.53	0.29	6.12	12.82	0.67
2246047	-22.02	-46.30	1127	0.59	0.35	5.51	10.41	-0.91
2246050	-22.60	-46.03	894	0.39	0.15	6.05	10.89	0.80
2246056	-22.32	-46.32	856	0.60	0.36	6.09	11.24	-1.59
2246057	-22.76	-46.14	1041	0.56	0.31	5.66	11.69	-0.98
2246127	-22.27	-46.16	905	0.64	0.42	5.31	9.59	-0.68
Média 1	-21.80	-46.13	987	0.52	0.27	4.44	8.59	3.21
Média 2	-22.85	-46.24	1031	0.65	0.42	4.71	8.41	-0.96

4.2.3 Análise para a estação de inverno

Serão apresentados nessa seção os resultados das estatísticas calculadas para os meses de inverno (junho – julho – agosto) de todo o período de dados. O inverno é considerado a estação seca da região de estudo e é a estação com os menores acumulados de precipitação (Reboita *et al.*, 2015; Torres *et al.*, 2020). Deste modo, espera-se que os valores das estatísticas sejam mais altas do que os valores encontrados para a série completa e para o verão.

De acordo com as Figuras 12a e 13a, onde encontram-se os valores da correlação de Pearson, pode-se dizer que a maioria dos pontos se localizam no intervalo de 0,5 a 0,9, indicando correlações de moderada a alta; poucos pontos ficam abaixo desse intervalo, indicando correlações de fraca a muito fraca. Observando a Tabela 8, o menor valor dessa estatística é 0,01 para a cidade de São Bento do Sapucaí (2245011). O maior valor de correlação foi de 0,89 para Média 1 das estações. De maneira geral, a correlação foi mais alta para o inverno quando comparada com as demais análises – série completa e verão, tendo média de 0,64. Esses resultados já eram esperados, pois como a ocorrência de precipitação nessa estação é muito reduzida, as chances de o GPM estimar erroneamente reduzem.

Os valores do R^2 , encontrados nas Figuras 12b e 13b, variaram, em sua maioria, de 0,40 a 0,80. De todas as análises apresentadas, o inverno foi o período com os maiores valores do R^2 . O menor valor dessa estatística foi 0,0 para São Bento do Sapucaí (2245011), mesma cidade que apresentou o menor valor de correlação. O valor mais alto do R^2 foi de 0,78 para Carmo da Cachoeira (2145044) e Média 1 das estações, assim como para a correlação (Tabela 8). O R^2 , no geral, teve valores mais altos para o inverno, mostrando que a capacidade explicativa do GPM para a ANA é um pouco melhor nessa estação.

O MAE é apresentado nas Figuras 12c e 13c e, assim como as demais estatísticas, os melhores valores foram encontrados no inverno. Seus valores variaram de 0,40 mm dia⁻¹ a 1,80 mm dia⁻¹, sendo um bom resultado, visto que quanto mais próximo de zero, melhor. O menor valor do MAE foi de 0,41 mm dia⁻¹ para a Média 1 das estações, que também recebeu o maior valor da correlação e do R^2 . O pior valor, sendo o mais alto, foi de 1,79 mm dia⁻¹ para Campos do Jordão (2245010) (Tabela 8). Como os valores dessa estatística foram menores para o inverno, quando comparado com a série completa e o verão, as discrepâncias entre o GPM e a ANA são menores para essa estação.

Assim como para o MAE, a RMSE é menor no inverno. Através das Figuras 12d e 13d, observa-se que esses valores variam entre 1,50 mm dia⁻¹ e 6,0 mm dia⁻¹, o que é bem abaixo do intervalo encontrado para as demais análises. O valor mais baixo dessa estatística foi de 1,62 mm dia⁻¹ para Monsenhor Paulo (2145017), que também obteve a maior correlação e R² e menor MAE, já o valor mais alto foi de 5,74 mm dia⁻¹ para Campos do Jordão (2245010). Devido os resultados da RMSE ficarem mais baixos do que ficaram para a série completa e para o verão, assim como foi dito acima para o MAE, as diferenças entre esses dados foram menores no inverno.

Os valores do BIAS se encontram nas Figuras 12e 13e e foram mais baixos também para essa estação, variando entre -0,40 e 1,0 (Figura 12e). Assim como ocorreu para as demais análises, essa estatística não possui um padrão, pois o GPM acaba subestimando e superestimando os dados da ANA. Mesmo não possuindo um padrão, a quantidade de estações em que o GPM superestima é maior do que a que subestima. Analisando a Tabela 8, o menor valor do BIAS foi 0,00 para Monsenhor Paulo (2145017) e Santa Rita do Sapucaí (2245000), indicando então que para essa estação, o GPM não obteve nenhuma tendência de subestimar ou superestimar. O valor mais alto do BIAS positivo foi de 0,93 para São Bento do Sapucaí (2245011), que também obteve a menor correlação e um R² nulo (0,00), já o valor mais baixo, acima do zero foi de 0,01 para Cambuquira (2145008). O Bias negativo mais alto foi de -0,31 para Delfim Moreira (2245064), já o mais baixo e próximo de zero foi de -0,01 para Careaçú (2245074). Com esses resultados do BIAS, observou-se que, assim como ocorreu para a estação de verão, o satélite superestimou a precipitação em superfície na maior parte das estações, porém em alguns casos houve subestimação. Como os valores para o inverno foram mais baixos, indica que a superestimação e a subestimação foram menores quantitativamente.

Assim como era esperado os piores valores das estatísticas para a estação de verão, era esperado os melhores para o inverno, visto que essa estação é considerada seca na região. Após analisar os resultados gerados, concluiu-se que os melhores valores foram de fato encontrados para essa estação, pois a ρ e o R² atingiram valores mais altos, o MAE, a RMSE e o BIAS tiveram os menores valores encontrados também. Deste modo, verificou-se que o satélite possui uma melhor capacidade em estimar a precipitação nos meses mais secos, com pouco registro de precipitação.

No trabalho de Hashemi *et al.* (2017), assim como foi encontrado que as piores estatísticas foram para o inverno – estação chuvosa na região, os melhores valores foram para a estação de verão, pois é a estação mais seca e sem chuva na região. Deste modo, como o inverno também é uma estação mais seca e sem chuva na BHRS, os valores das estatísticas são melhores para essa estação.

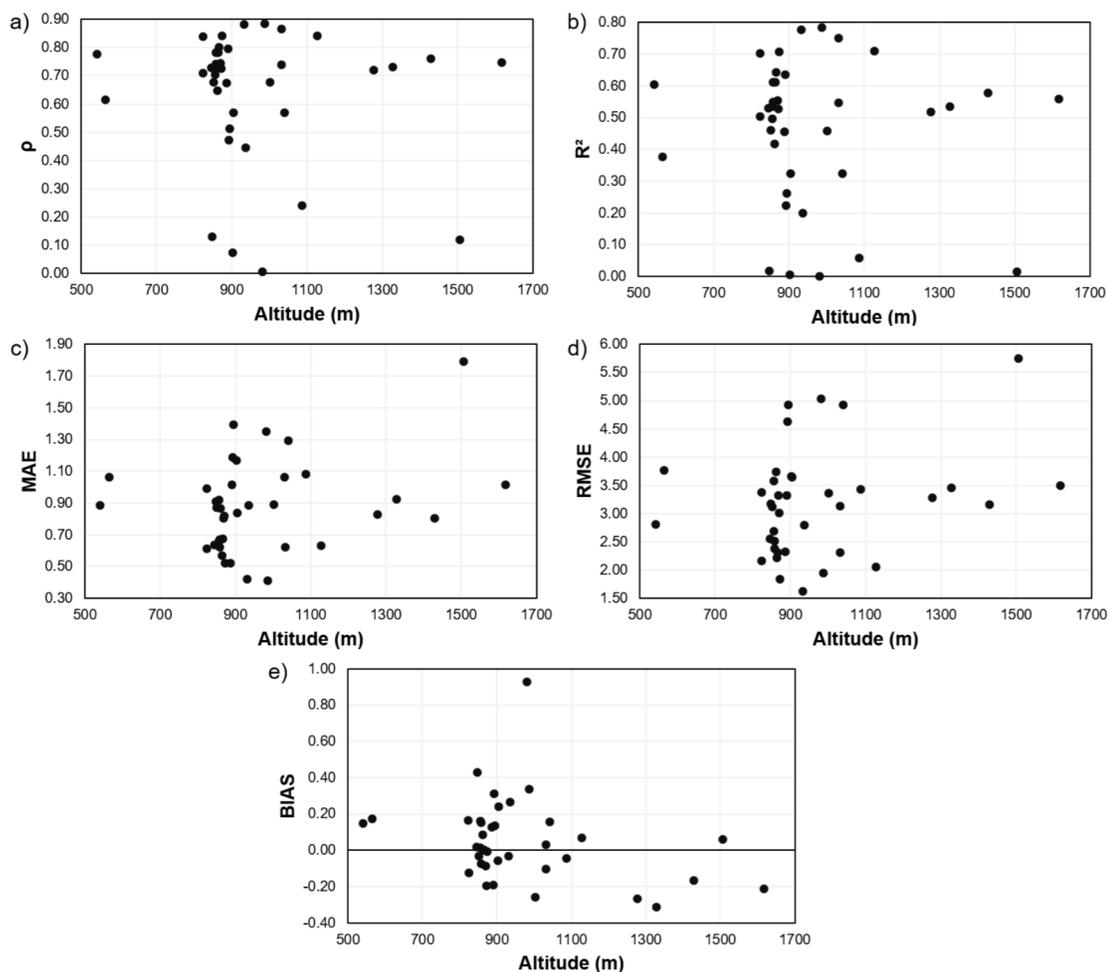


Figura 12 – Métricas estatísticas calculadas para a estação de inverno: a) Correlação de Pearson; b) R^2 ; c) MAE; d) RMSE; e) BIAS

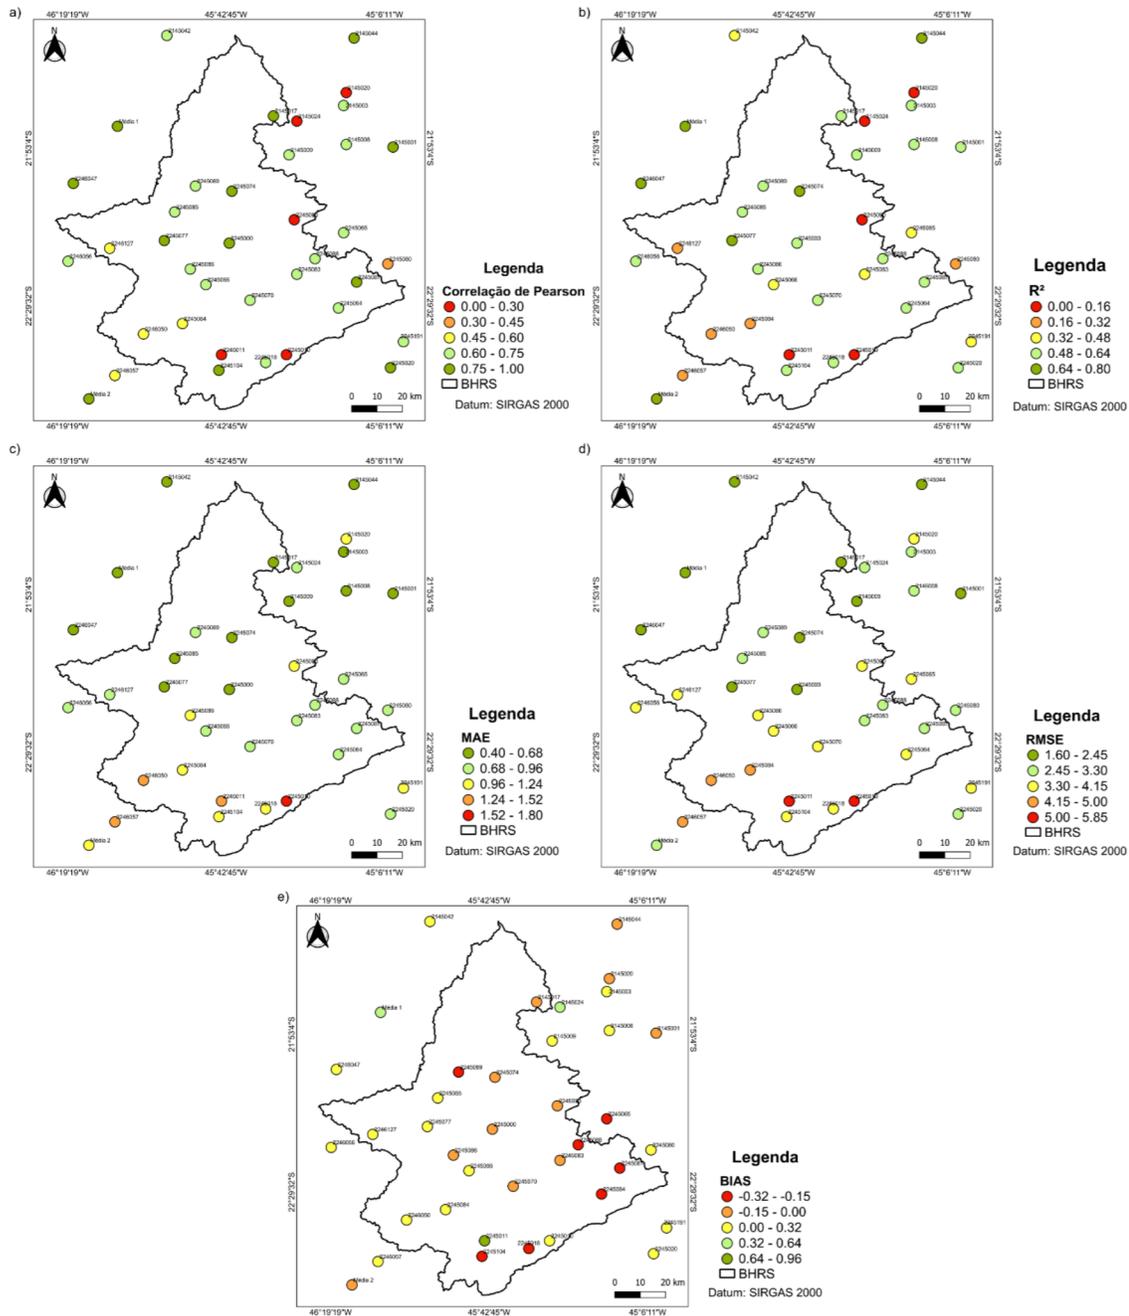


Figura 13 – Mapas das estatísticas calculadas para a estação de inverno: a) Correlação de Pearson; b) R²; c) MAE; d) RMSE; e) BIAS

Tabela 8 – Informações das estações da ANA e valores das estatísticas calculadas para o inverno para avaliar o desempenho da precipitação diária do GPM em relação a ANA. Destacados em vermelho (azul) indicam pior (melhor) desempenho

Estação	Latitude	Longitude	Altitude	ρ	R^2	MAE	RMSE	BIAS
2145001	-21.88	-45.07	858	0.78	0.61	0.62	2.38	-0.08
2145003	-21.72	-45.26	845	0.73	0.53	0.64	2.55	0.02
2145008	-21.87	-45.25	856	0.73	0.53	0.66	2.69	0.01
2145009	-21.91	-45.47	1032	0.74	0.55	0.62	2.31	0.03
2145017	-21.76	-45.53	864	0.78	0.61	0.57	2.22	0.00
2145020	-21.67	-45.25	902	0.07	0.01	1.17	3.66	-0.06
2145024	-21.78	-45.44	848	0.13	0.02	0.91	3.18	0.43
2145042	-21.45	-45.94	887	0.67	0.46	0.52	2.33	0.13
2145044	-21.46	-45.22	932	0.88	0.78	0.42	1.62	-0.03
2245000	-22.25	-45.70	866	0.80	0.64	0.67	2.31	0.00
2245010	-22.68	-45.48	1506	0.12	0.01	1.79	5.74	0.06
2245011	-22.68	-45.73	981	0.01	0.00	1.35	5.04	0.93
2245018	-22.71	-45.56	1617	0.75	0.56	1.01	3.50	-0.21
2245020	-22.73	-45.08	541	0.78	0.61	0.89	2.81	0.15
2245064	-22.50	-45.28	1328	0.73	0.54	0.92	3.46	-0.31
2245065	-22.21	-45.26	1002	0.68	0.46	0.89	3.37	-0.26
2245066	-22.41	-45.79	861	0.65	0.42	0.86	3.75	0.09
2245070	-22.47	-45.62	869	0.74	0.55	0.80	3.33	-0.09
2245074	-22.05	-45.69	873	0.84	0.71	0.52	1.84	-0.01
2245077	-22.24	-45.95	823	0.84	0.70	0.61	2.16	0.16
2245080	-22.33	-45.09	936	0.45	0.20	0.88	2.80	0.26
2245083	-22.37	-45.44	851	0.68	0.46	0.87	3.12	-0.03
2245084	-22.56	-45.88	893	0.47	0.22	1.19	4.62	0.31
2245085	-22.13	-45.91	858	0.74	0.55	0.67	2.52	0.15
2245086	-22.35	-45.85	824	0.71	0.50	0.99	3.37	-0.13
2245087	-22.40	-45.21	1429	0.76	0.58	0.80	3.15	-0.17
2245088	-22.31	-45.37	1277	0.72	0.52	0.83	3.28	-0.27
2245089	-22.03	-45.83	871	0.73	0.53	0.82	3.01	-0.20
2245090	-22.16	-45.45	1087	0.24	0.06	1.08	3.43	-0.04
2245104	-22.74	-45.74	890	0.80	0.63	1.02	3.32	-0.19
2245191	-22.63	-45.03	564	0.61	0.38	1.06	3.77	0.17
2246047	-22.02	-46.30	1127	0.84	0.71	0.63	2.06	0.07
2246050	-22.60	-46.03	894	0.51	0.26	1.39	4.93	0.14
2246056	-22.32	-46.32	856	0.70	0.50	0.92	3.57	0.16
2246057	-22.76	-46.14	1041	0.57	0.32	1.29	4.92	0.15
2246127	-22.27	-46.16	905	0.57	0.32	0.84	3.65	0.24
Média 1	-21.80	-46.13	987	0.89	0.78	0.41	1.94	0.33
Média 2	-22.85	-46.24	1031	0.87	0.75	1.06	3.14	-0.10

4.3 Análise Pixel a Ponto

Para essa análise, o primeiro passo foi a construção das curvas de permanência, que se encontram nas Figuras 14 e 15. O próximo passo foi a remoção de viés dos dados do GPM pelo método IQD, e já com as novas séries de dados do GPM, foram criadas as novas curvas de permanência (Figuras 16 e 17) e também calculadas as estatísticas (Figuras 18 e 19 e Tabela 9).

Analisando as Figuras 14 e 15, para todos os pontos, acima da porcentagem de tempo de 40% a frequência de precipitação é muito baixa, quase nula. Já a porcentagem de tempo abaixo de 10% é onde se encontram os maiores valores de precipitação. Sendo assim, nota-se que de toda a série de dados, a maior parte possui acumulado diário de precipitação muito baixa ou nula. No geral, as curvas da ANA e do GPM tiveram comportamento semelhante, porém é possível observar algumas discrepâncias entre elas. Após a correção dos dados do GPM, Figuras 16 e 17, houve uma melhora no comportamento entre as curvas do GPM e da ANA, pois onde havia consideráveis discrepâncias melhorou. Dessa forma, a interpolação nos dados do GPM auxiliou na melhoria da frequência de precipitação.

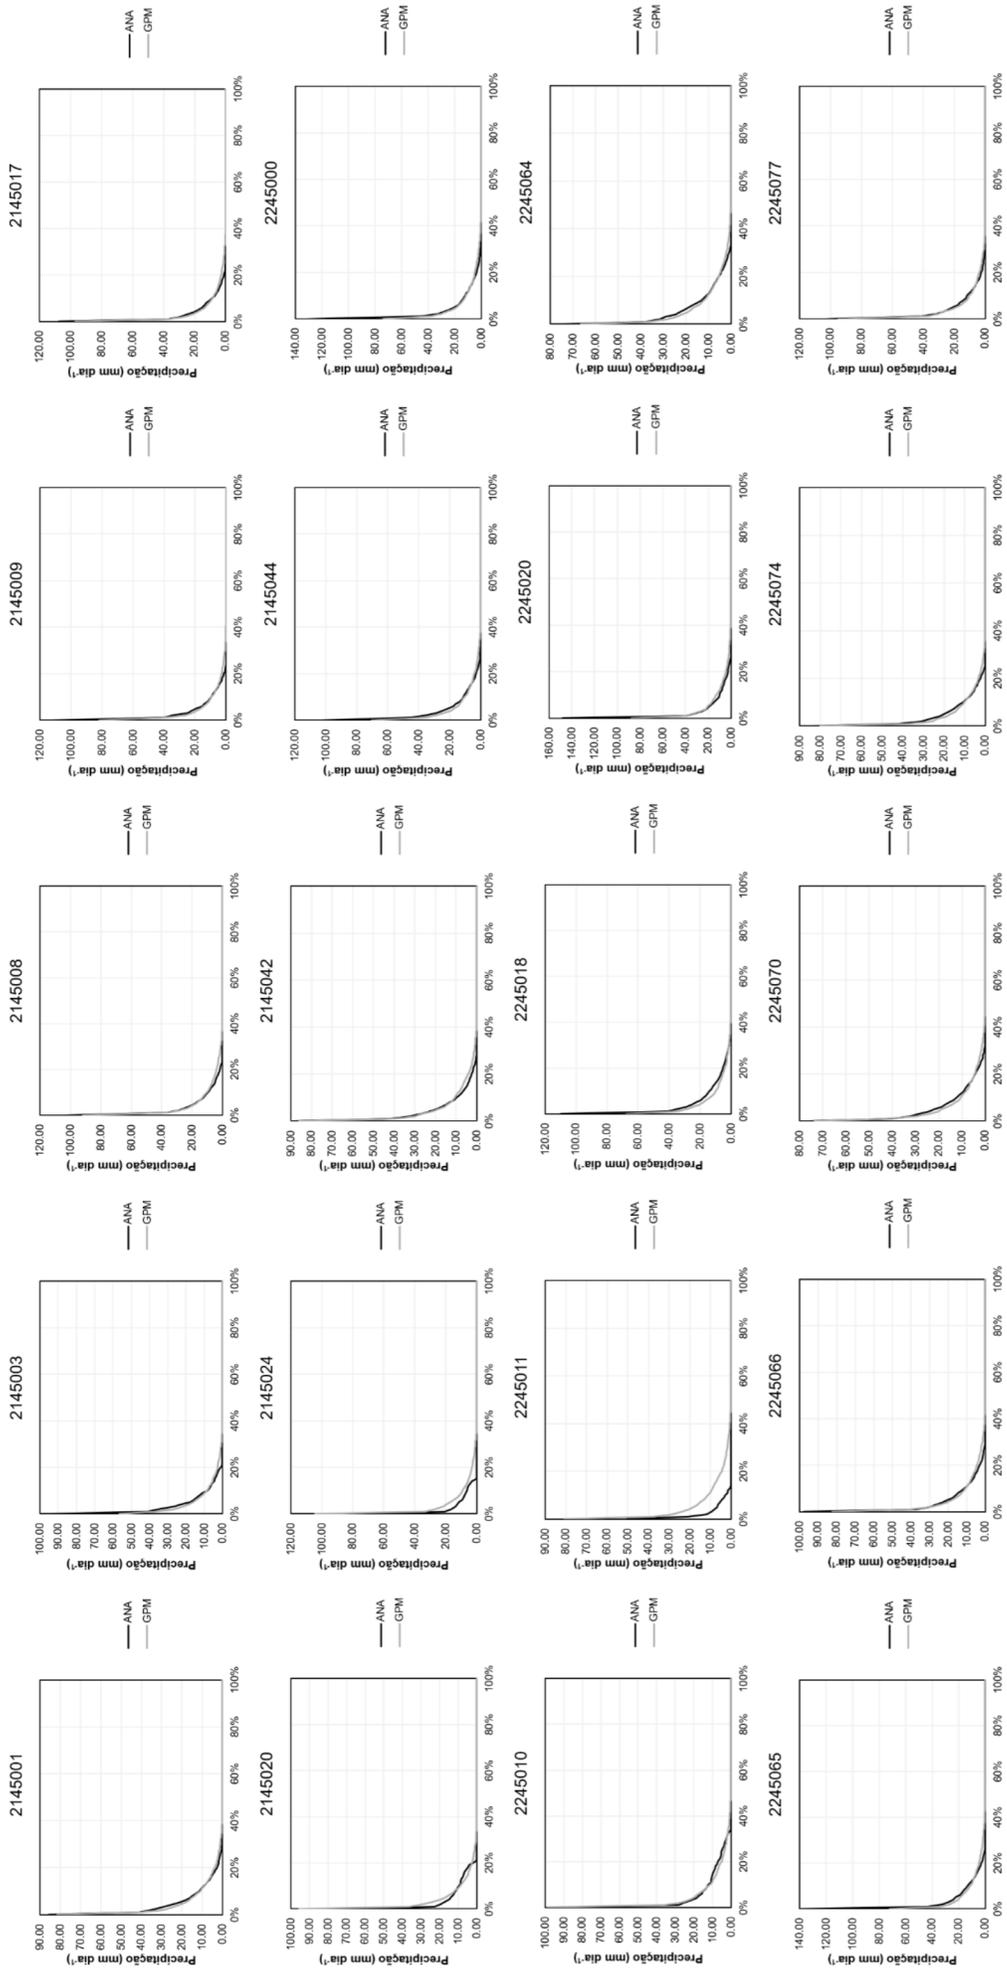


Figura 14 – Curvas de permanência para cada ponto antes da interpolação

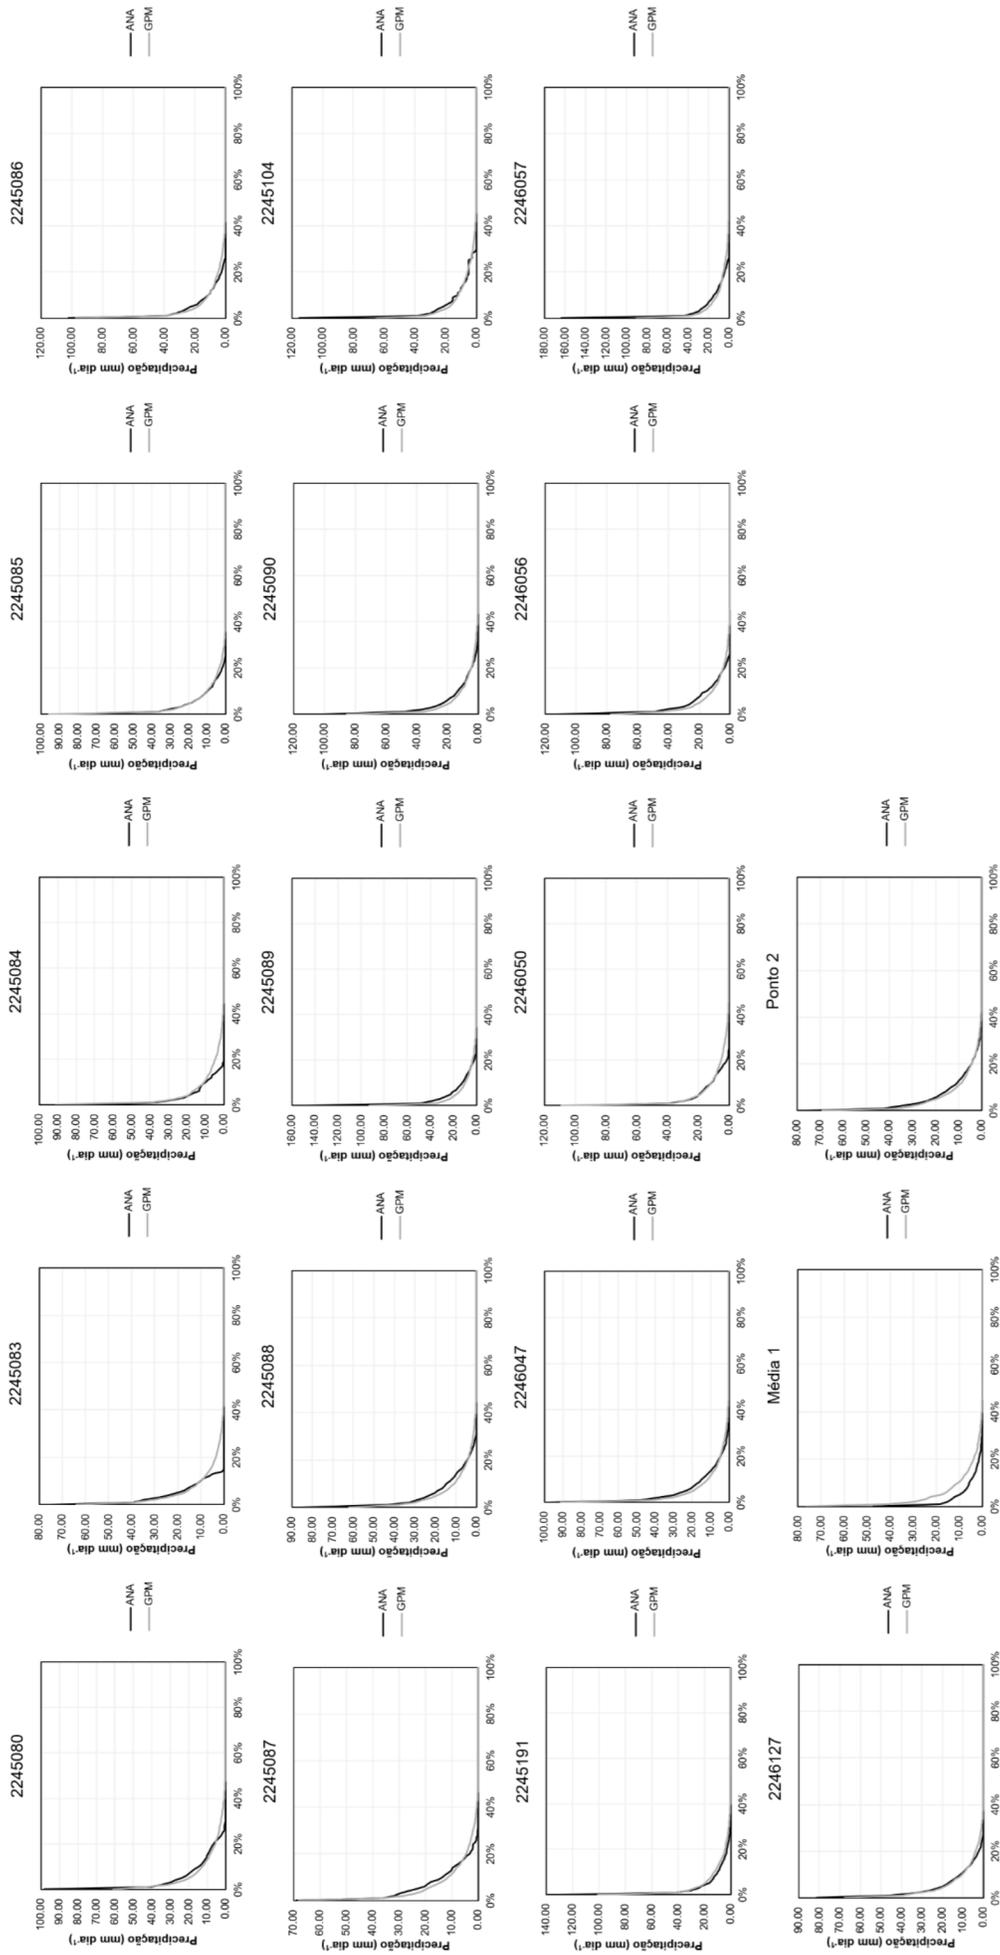


Figura 15 – Curvas de permanência para cada ponto antes da interpolação

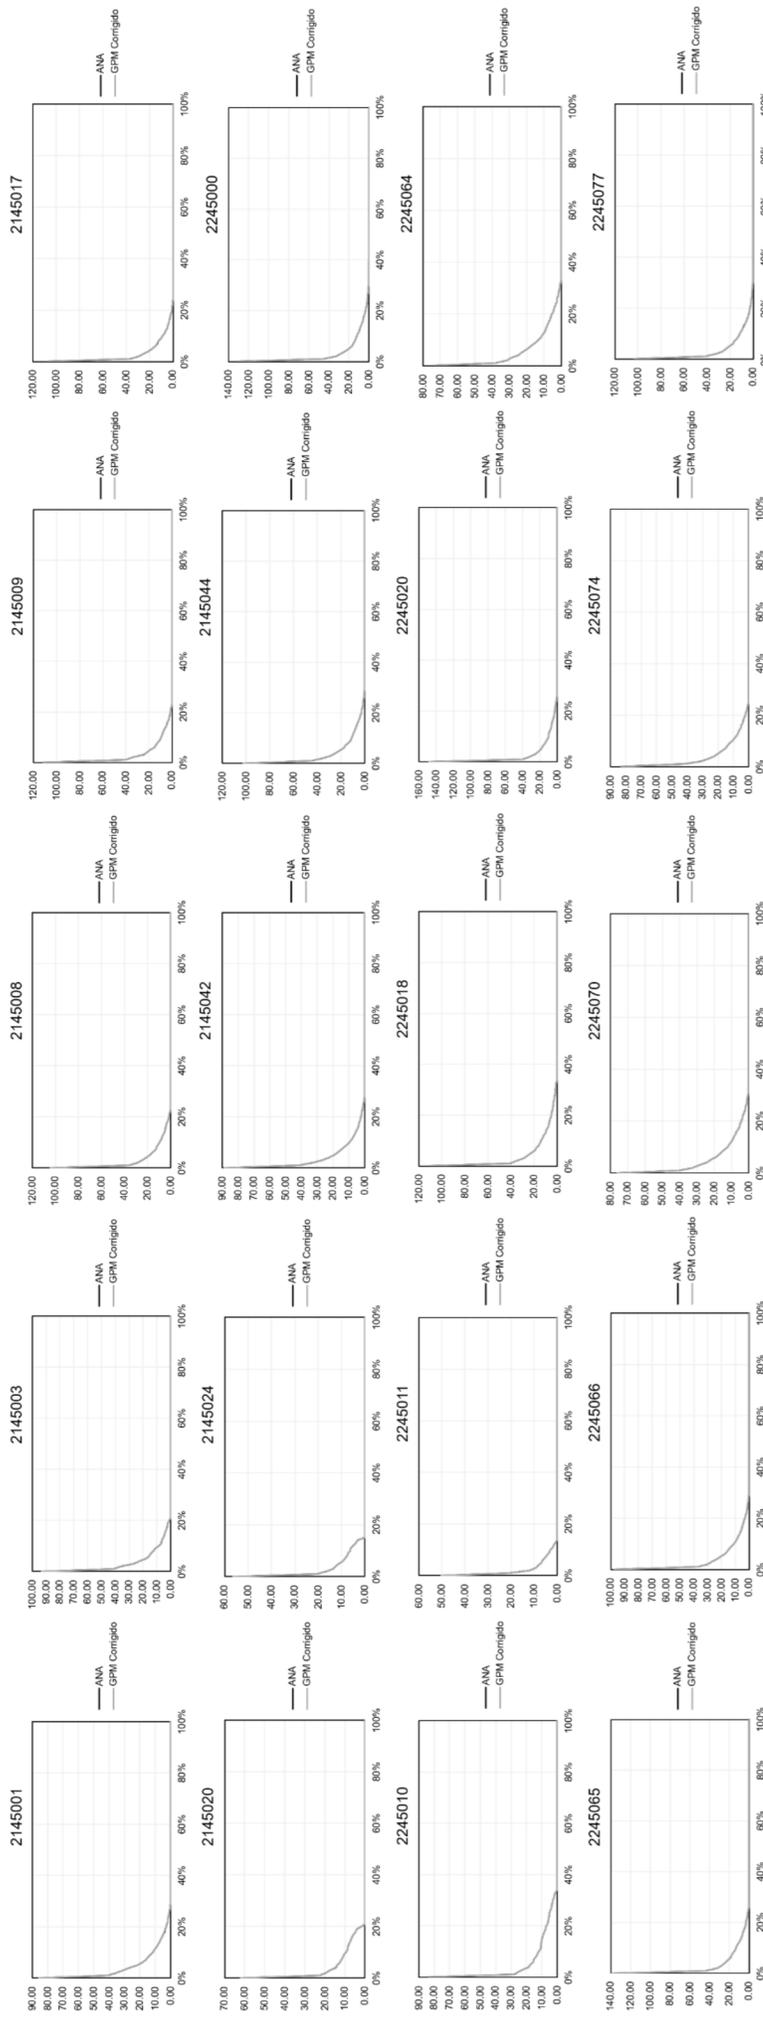


Figura 16 – Curvas de permanência para cada ponto depois da interpolação

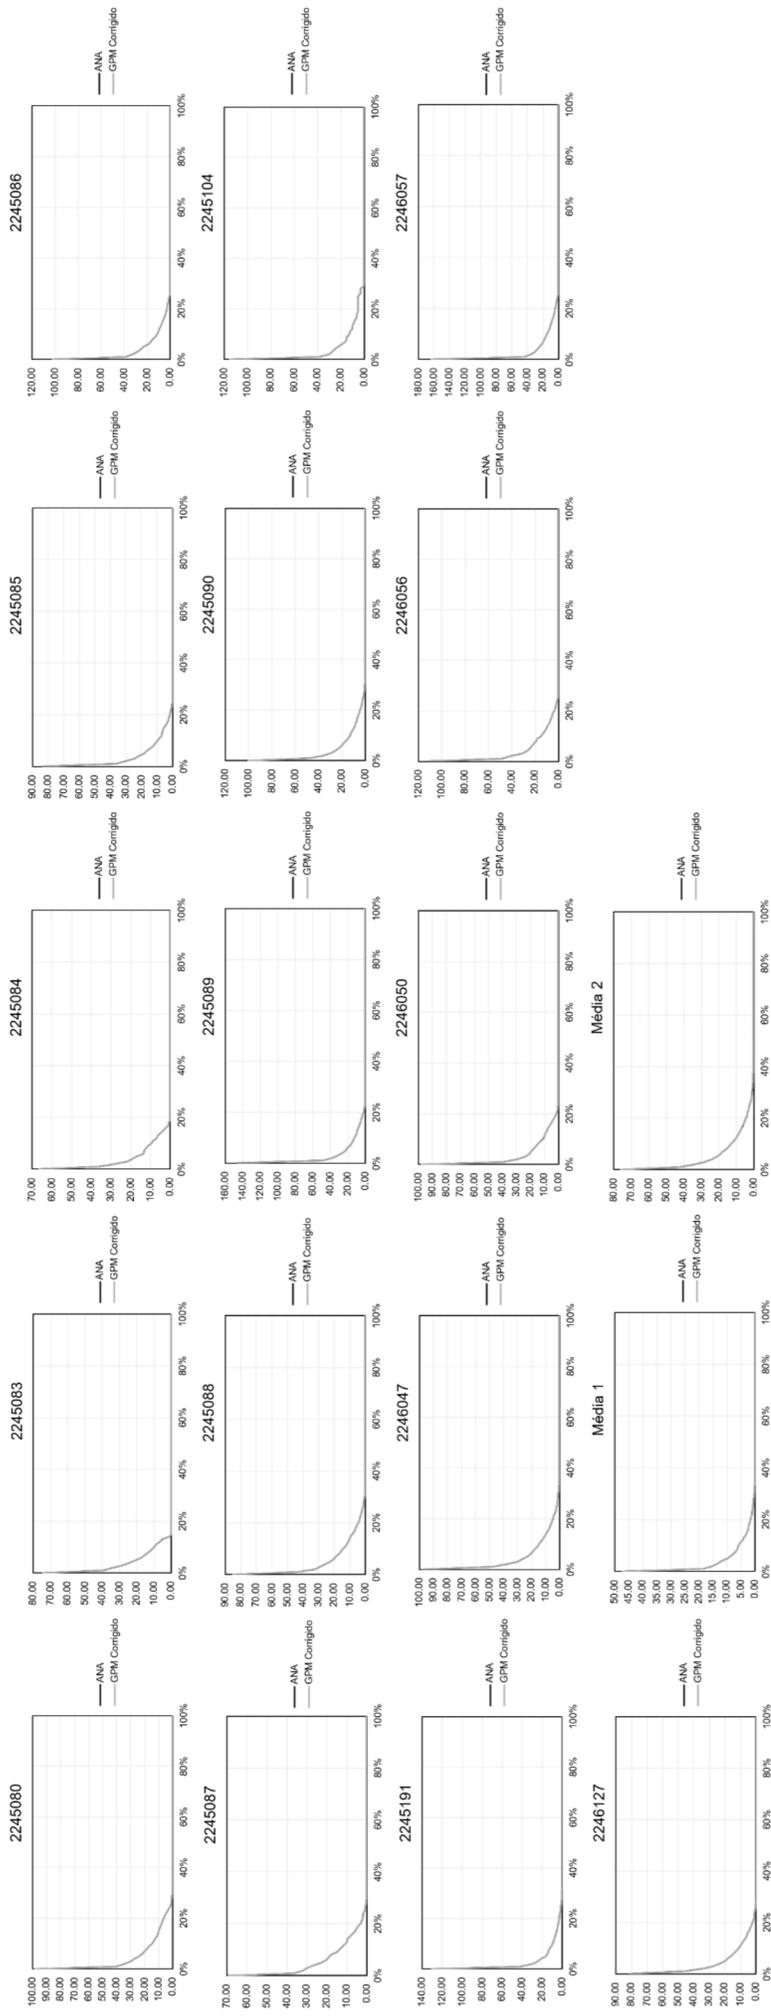


Figura 17 – Curvas de permanência para cada ponto depois da interpolação

As Figuras 18 e 19 e a Tabela 9 apresentam os valores das estatísticas calculadas utilizando os dados do GPM com viés removido. As correlações (Figuras 18a e 19a) variaram, em sua maioria, no intervalo de 0,40 a 0,80. A cidade com o valor mais baixo foi São Bento do Sapucaí (2245011) com 0,18 e a de maior valor foi Careaçú (2245074) 0,76 (Tabela 9). Para a série completa considerando o método ponto a pixel, Careaçú também obteve o maior valor de correlação. A média dessa estatística foi de 0,57, e comparando com a série completa, observa-se que os valores ficaram bem próximos (0,58). Sendo assim, em média, a correlação encontrada para esse método foi moderada.

O R^2 (Figuras 18b e 19b) apresentou maiores quantidades de pontos no intervalo de 0,30 a 0,60, com o menor valor encontrado para a cidade de São Bento do Sapucaí (2245011), com 0,03, e o maior para as cidades de Careaçú (2245074) e Pouso Alegre (2245077), com 0,57 (Tabela 9). A média dessa estatística também ficou parecida com a da série completa, sendo de 0,35 e 0,36 respectivamente. Como a média do R^2 foi baixa, isso mostra que os dados do GPM possuem uma baixa capacidade explicativa para os dados de precipitação.

Os valores do MAE (Figuras 18c e 19c) variaram, em sua maioria, de 1,50 mm dia⁻¹ a 4,50 mm dia⁻¹, e a sua média foi um pouco mais baixa do que para a série completa, sendo de 2,96 mm dia⁻¹, enquanto que para a série completa foi de 3,02 mm dia⁻¹. A Média 1 das estações foi a que obteve o menor valor do MAE, sendo de 1,29 mm dia⁻¹, enquanto que Conceição das Pedras (2245090) ficou com o maior valor, 5,18 mm dia⁻¹ (Tabela 9). Assim como para a série completa, nenhum ponto se aproximou de zero. Deste modo, os dados do GPM possuem diferenças dos dados da ANA.

A RMSE encontra-se nas Figuras 18d e 19d, e variou de 3,41 mm dia⁻¹ a 12,04 mm dia⁻¹ (Tabela 9), sendo que a maioria dos pontos se encontra no intervalo de 5,0 mm dia⁻¹ a 10,0 mm dia⁻¹. O valor mais baixo dessa estatística foi para a Média 1 das estações, e o valor mais alto foi para a cidade de Conceição das Pedras (2245090), assim como ocorreu para o MAE. Para a série completa, a cidade com os maiores valores do MAE e da RMSE também foi Conceição das Pedras. A média da RMSE foi de 7,57, valor um pouco mais elevado do que para a série completa (7,35 mm dia⁻¹), mostrando então que existem discrepâncias entre os dois conjuntos de dados.

O BIAS (Figuras 18e e 19e) variou de -0,09 a 0,16 (Tabela 9). De acordo com as Figuras 18e e 19e, não existe um padrão do GPM subestimar ou superestimar a

precipitação em solo, pois ocorrem ambos os casos. Porém, existem mais pontos de superestimação (18) do que de subestimação (15), e ainda existem 5 pontos com valores 0,0, indicando que não há padrão de subestimar ou superestimar. As cidades que tiveram o valor mais alto negativamente foram: Alfenas (2145042) e Cachoeira Paulista (2245191), com -0,09, já com o valor mais baixo negativamente foram: Cambuquira (2145008), Delfim Moreira (2245064), Pouso Alegre (2245077), Silvianópolis (2245089) e a Média 1 das estações, com valor de -0,01. A cidade com valor mais alto positivamente (0,16) foi Sapucaí-Mirim (2245104), enquanto que as de valor mais baixo (0,01) foram: Campanha (2145009), São Bento do Sapucaí (2245011), Virgínia (2245080), Pouso Alegre (2245086). As cidades: Três Corações (2145003), Monsenhor Paulo (2145017), Campos do Jordão (2245010), Brasópolis (2245070) e Borda da Mata (2246127), não apresentaram tendências de superestimar ou subestimar. No geral, mesmo sem a existência de um padrão, os dados do GPM superestimam, em sua maioria, os dados da ANA.

Medeiros-Feitosa e Oliveira (2020), que realizaram uma comparação entre os dados do TRMM e de estações para o estado do Ceará, utilizando essa mesma metodologia, porém para dados mensais, encontraram uma correlação de 0,89, MAE de 29,10, RMSE de 48,14 e BIAS de 8,93. Assim como ocorreu para esse estudo, os autores encontraram um padrão de superestimação do satélite em relação aos dados pluviométricos em solo.

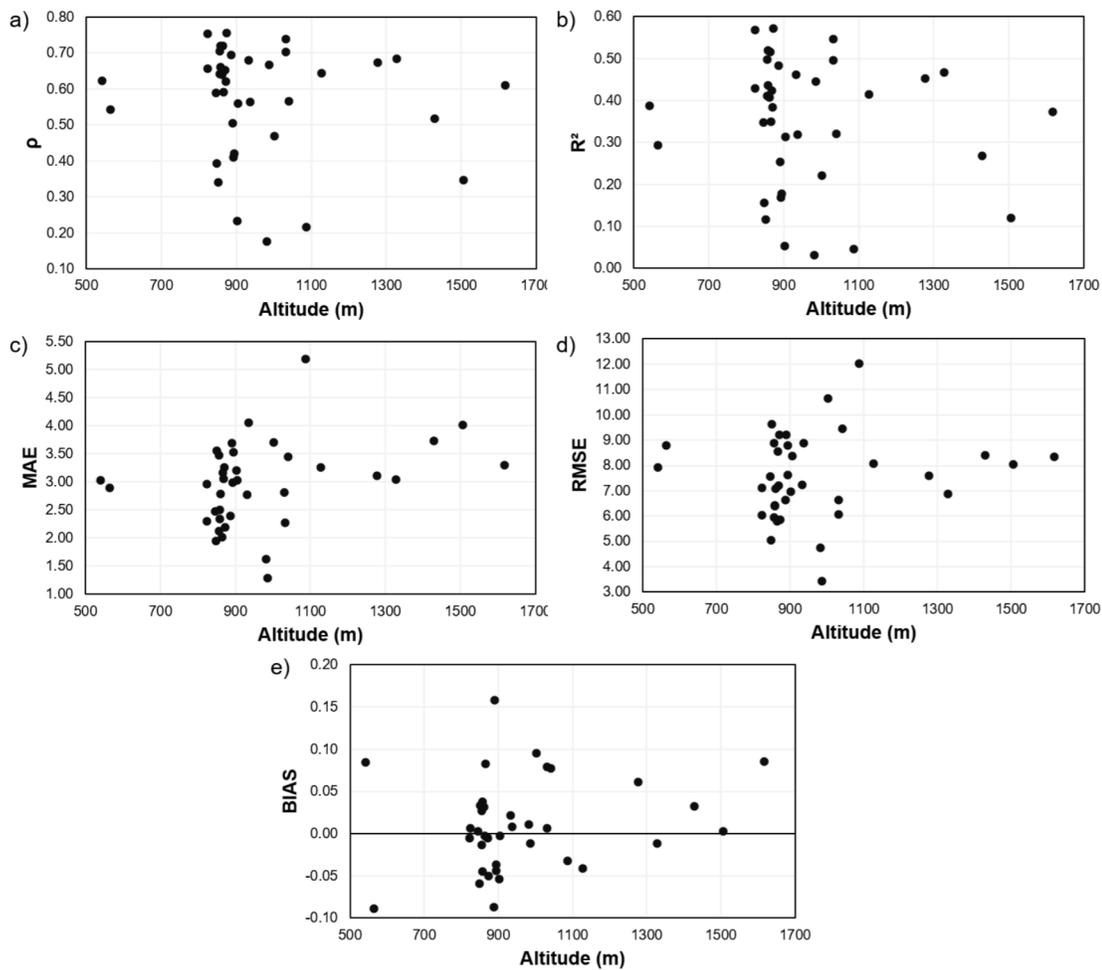


Figura 18 – Métricas estatísticas calculadas para a série completa, pela metodologia pixel a ponto: a) Correlação de Pearson; b) R^2 ; c) MAE; d) RMSE; e) BIAS

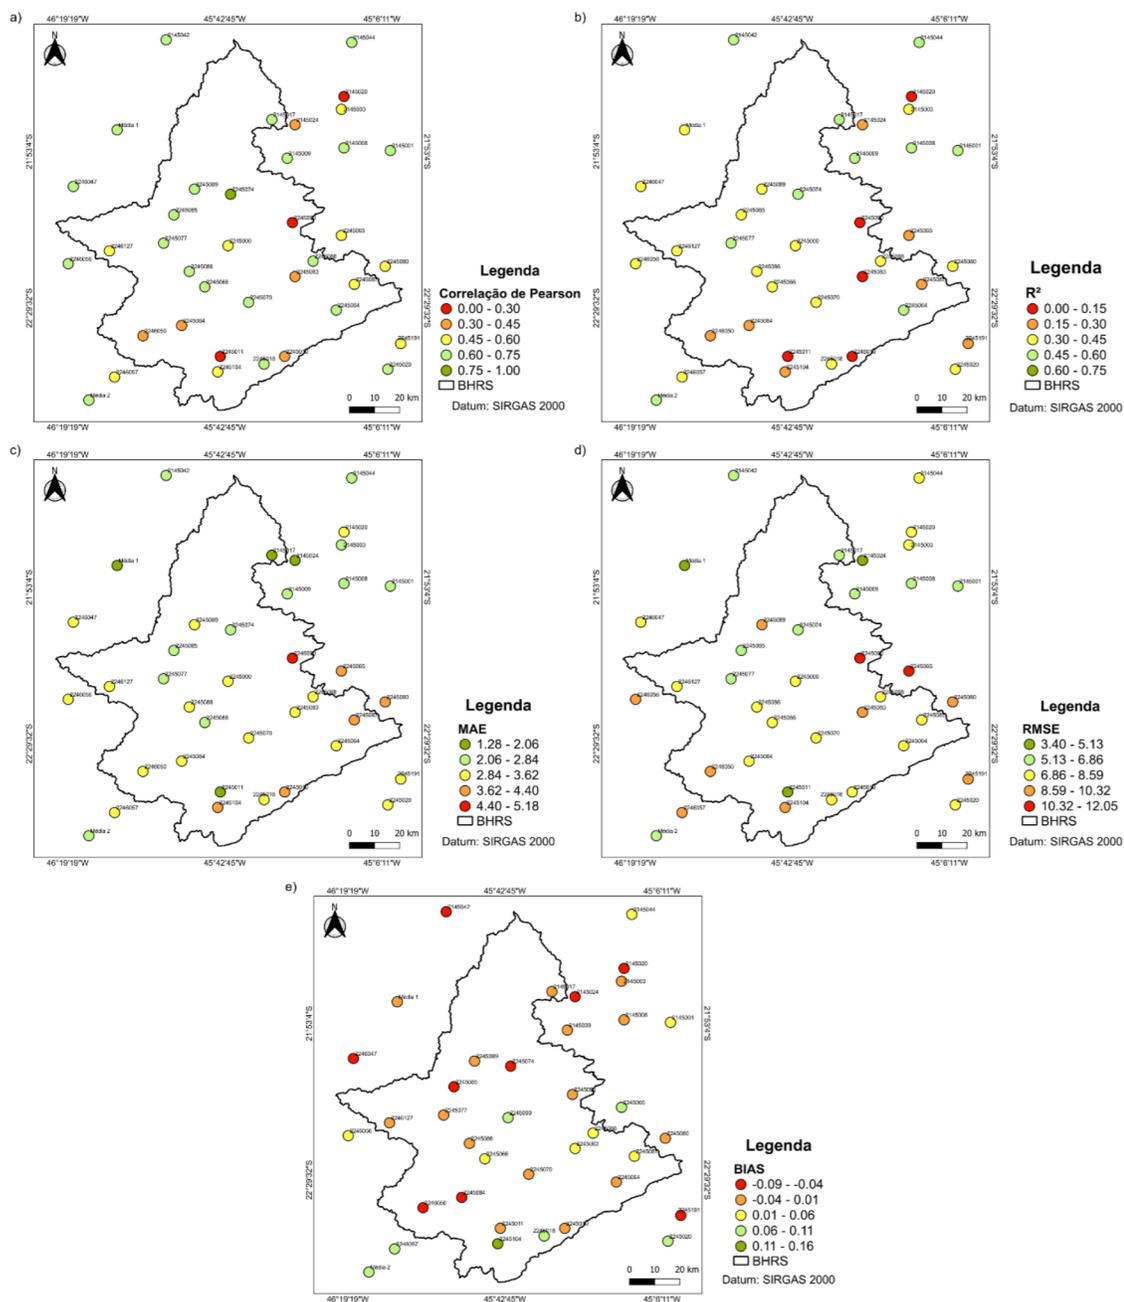


Figura 19 – Mapas das estatísticas pelo método pixel a ponto: a) Correlação de Pearson; b) R²; c) MAE; d) RMSE; e) BIAS

Tabela 9 – Informações das estações da ANA e valores das estatísticas calculadas para o método pixel a ponto, para avaliar o desempenho da precipitação diária do GPM em relação a ANA. Destacados em vermelho (azul) indicam pior (melhor) desempenho

Estação	Latitude	Longitude	Altitude	ρ	R^2	MAE	RMSE	BIAS
2145001	-21.88	-45.07	858	0.72	0.52	2.50	6.42	0.04
2145003	-21.72	-45.26	845	0.59	0.35	2.48	7.56	0.00
2145008	-21.87	-45.25	856	0.71	0.50	2.13	5.96	-0.01
2145009	-21.91	-45.47	1032	0.74	0.55	2.27	6.06	0.01
2145017	-21.76	-45.53	864	0.72	0.52	2.02	5.80	0.00
2145020	-21.67	-45.25	902	0.23	0.05	3.21	6.96	-0.05
2145024	-21.78	-45.44	848	0.39	0.16	1.95	5.04	-0.06
2145042	-21.45	-45.94	887	0.70	0.48	2.39	6.64	-0.09
2145044	-21.46	-45.22	932	0.68	0.46	2.77	7.23	0.02
2245000	-22.25	-45.70	866	0.59	0.35	3.16	8.55	0.08
2245010	-22.68	-45.48	1506	0.35	0.12	4.01	8.05	0.00
2245011	-22.68	-45.73	981	0.18	0.03	1.62	4.74	0.01
2245018	-22.71	-45.56	1617	0.61	0.37	3.30	8.34	0.09
2245020	-22.73	-45.08	541	0.62	0.39	3.02	7.92	0.08
2245064	-22.50	-45.28	1328	0.68	0.47	3.05	6.88	-0.01
2245065	-22.21	-45.26	1002	0.47	0.22	3.71	10.64	0.10
2245066	-22.41	-45.79	861	0.64	0.41	2.78	7.09	0.03
2245070	-22.47	-45.62	869	0.65	0.42	3.05	7.21	0.00
2245074	-22.05	-45.69	873	0.76	0.57	2.19	5.84	-0.05
2245077	-22.24	-45.95	823	0.75	0.57	2.30	6.05	-0.01
2245080	-22.33	-45.09	936	0.56	0.32	4.06	8.89	0.01
2245083	-22.37	-45.44	851	0.34	0.12	3.55	9.62	0.03
2245084	-22.56	-45.88	893	0.41	0.17	2.98	7.63	-0.04
2245085	-22.13	-45.91	858	0.66	0.44	2.34	6.40	-0.05
2245086	-22.35	-45.85	824	0.66	0.43	2.97	7.12	0.01
2245087	-22.40	-45.21	1429	0.52	0.27	3.73	8.41	0.03
2245088	-22.31	-45.37	1277	0.67	0.45	3.11	7.60	0.06
2245089	-22.03	-45.83	871	0.62	0.38	3.25	9.21	-0.01
2245090	-22.16	-45.45	1087	0.22	0.05	5.18	12.04	-0.03
2245104	-22.74	-45.74	890	0.50	0.25	3.69	9.20	0.16
2245191	-22.63	-45.03	564	0.54	0.29	2.89	8.80	-0.09
2246047	-22.02	-46.30	1127	0.64	0.41	3.25	8.08	-0.04
2246050	-22.60	-46.03	894	0.42	0.18	3.53	8.78	-0.04
2246056	-22.32	-46.32	856	0.64	0.41	3.48	8.87	0.03
2246057	-22.76	-46.14	1041	0.57	0.32	3.45	9.44	0.08
2246127	-22.27	-46.16	905	0.56	0.31	3.02	8.38	0.00
Média 1	-21.80	-46.13	987	0.67	0.45	1.29	3.41	-0.01
Média 2	-22.85	-46.24	1031	0.70	0.50	2.81	6.64	0.08

4.4 Análise Pixel a Pixel

Para aplicar essa análise, extraiu-se os valores de todos os centros dos pixels dentro da região de estudo. Para os dados da ANA, foi realizado uma interpolação pelo método IQD, e após esse processo, todos os centros dos pixels tinham uma série de dados da ANA correspondente. Com ambas as séries disponíveis, aplicou-se as estatísticas de comparação, e os seus resultados encontram-se na Figura 20.

Os valores da correlação (Figura 20a) variaram de 0,25 a 0,77, e a maior parte dos pontos ficaram acima de 0,45. As regiões mais ao norte e oeste da bacia apresentaram valores superiores a 0,60 e a média das correlações foi de 0,63. Os resultados dessa estatística foram consideravelmente bons, visto que ficaram em intervalos de moderada a alta correlação.

A Figura 20b apresenta os valores do R^2 , que variou de 0,06 a 0,60, com a maior parte ficando entre o intervalo de 0,30 a 0,45. Seguindo o mesmo padrão da correlação, os maiores valores foram para o norte e oeste da bacia. A média do R^2 foi de 0,40, o que não é um valor considerável, visto que os melhores valores são próximos de 1.

Os valores do MAE encontram-se na Figura 20c. Para essa estatística os valores variaram de 1,97 mm dia⁻¹ a 4,50 mm dia⁻¹. Os menores valores do MAE também ficaram concentrados no norte e oeste, assim como ocorreu para a correlação e R^2 , e apenas um ponto mais ao leste ficou no intervalo de 3,99 mm dia⁻¹ a 4,50 mm dia⁻¹, indicando o valor mais alto. A média do MAE foi de 2,82 mm dia⁻¹, e ficou mais baixa do que a média da série completa para o método ponto a pixel, que foi de 3,02 mm dia⁻¹. Sendo assim, as diferenças entre os dados do GPM e da ANA foram menores.

Através da Figura 20d observa-se que os valores da RMSE, onde os valores variaram de 5,05 mm dia⁻¹ a 10,51 mm dia⁻¹. Analisando a Figura 20c e 20d nota-se que ambas são semelhantes, pois onde os valores do MAE são menores, também se encontram os menores (melhores) valores da RMSE. Deste modo, os valores mais baixos dessa estatística são para o norte e oeste também, além disso, o mesmo ponto que obteve o maior valor do MAE também recebeu o maior valor da RMSE. A média da RMSE foi de 6,72 mm dia⁻¹, valor um pouco mais alto do que para a série completa (7,35 mm dia⁻¹), indicando que houve um pouco mais de discrepâncias entre os dados para esse método.

A Figura 20e apresenta os valores do BIAS, que para esse método variaram de -0,74 a 1,96, sendo esse intervalo menor do que para a série completa, que variou de -0,75 a 2,41. Também é perceptível que não existe um padrão e os pontos ficam bastante divididos entre superestimar e subestimar, porém a quantidade que superestima é maior do que a que subestima a precipitação, o que difere do que foi encontrado para a série completa (padrão de subestimação).

Lelis, Bosquilia e Duarte (2018) aplicaram um estudo para a região leste de São Paulo, onde realizaram comparações pelo método pixel a pixel entre dados do GPM e estações pluviométricas. Os autores encontraram um padrão de superestimação em 68% e subestimação em 32% dos dados, o que coincide com os resultados encontrados nesse estudo, para a metodologia pixel a pixel.

Analisando os resultados de todas as estatísticas, observa-se que para a sub-bacia do Baixo Sapucaí (norte da bacia) os valores são melhores: maiores correlações e R^2 e menores MAE e RMSE. De acordo com as Figuras 5 e 6, o Baixo Sapucaí possui as menores médias e acumulados de precipitação, sendo um fator contribuinte para justificar os melhores resultados, uma vez que, quanto menos chuva, menos chance de o satélite estimar a precipitação erroneamente. No Alto Sapucaí, encontram-se as correlações e R^2 mais baixos da bacia e os maiores erros, isso porque é nessa sub-bacia que se encontram as maiores altitudes (Figura 2), inclusive a Serra da Mantiqueira, que acabam influenciando nas estimativas do satélite, gerando erros (SILVA; VALERIANO, 2005; ANDERS *et al.*, 2006; HASHEMI *et al.*, 2017).

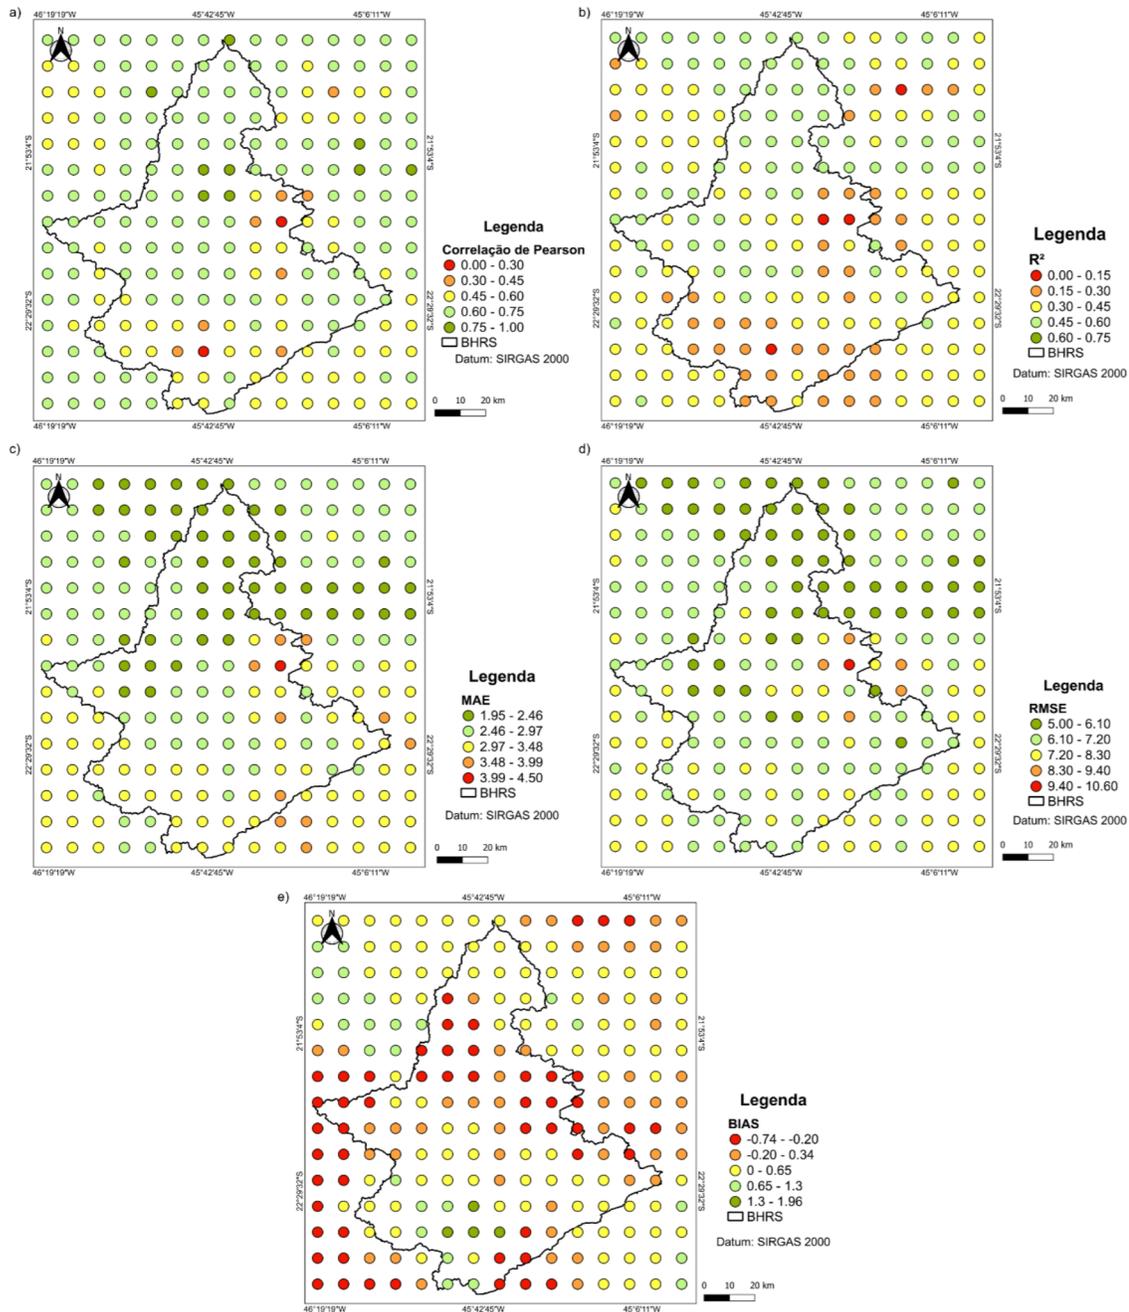


Figura 20 – Mapas das estatísticas pelo método pixel a pixel: a) Correlação de Pearson; b) R²; c) MAE; d) RMSE; e) BIAS

4.5 Análise por Média na Área

As três subáreas utilizadas para realizar os cálculos estatísticos estão representadas na Figura 21, onde a caixa azul representa o Baixo Sapucaí, a caixa verde o Médio Sapucaí e a caixa vermelha o Alto Sapucaí.

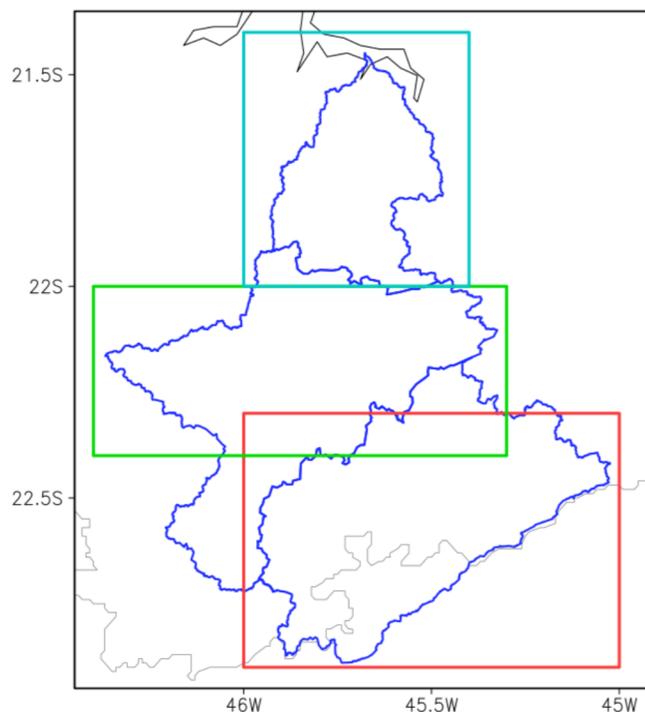


Figura 21 – Mapa da BHRs com as divisões em: Alto Sapucaí (caixa vermelha), Médio Sapucaí (caixa verde) e Baixo Sapucaí (caixa azul)

Nessa etapa, foram utilizadas as séries de dados da ANA da interpolação para o método pixel a pixel. Desta forma, para cada pixel do satélite havia uma série de dados da ANA. Foi aplicado uma média para os dados diários da ANA e do GPM e, após isso, aplicou-se as estatísticas para comparação. Os valores dessas estatísticas encontram-se na Tabela 10. De acordo com a tabela, os valores da correlação foram altos para todas as subáreas (de 0,79 a 0,83), o R^2 apresentou valores consideravelmente altos (de 0,63 a 0,69), já o MAE e a RMSE variaram de 1,79 mm dia⁻¹ a 2,06 mm dia⁻¹ e 3,92 mm dia⁻¹ a 4,26 mm dia⁻¹, respectivamente, os valores do BIAS foram baixos e próximos de zero, indicando que há pouca subestimação e superestimação quantitativamente. A subárea que apresentou os menores erros e a menor superestimação quantitativamente (BIAS positivo) da precipitação foi o Baixo Sapucaí, e isso pode estar ligado ao fato de que essa região possui os menores totais de precipitação (Figuras 5 e 6) e há uma menor variação de altitude (Figura 2). O Alto Sapucaí apresentou os valores mais baixos de correlação e R^2 , os maiores erros e a maior superestimação, e é nessa região é onde se tem uma maior variação de altitude e é onde se localiza as maiores altitudes (Serra da Mantiqueira). O Médio Sapucaí apresentou correlação e R^2 iguais ao Baixo Sapucaí, porém com magnitudes de erros

mais altos e subestimação da precipitação em superfície, e como essa região apresentou os maiores acumulados de precipitação, conseqüentemente foi um maior desafio para o satélite estimar a precipitação corretamente.

Tabela 10 – Valores das estatísticas calculadas para cada subárea

Divisões da Bacia	ρ	R^2	MAE	RMSE	BIAS
Alto Sapucaí	0.79	0.63	2.06	4.26	0.30
Médio Sapucaí	0.83	0.69	1.98	3.99	-0.20
Baixo Sapucaí	0.83	0.69	1.79	3.92	0.10

Gadêlha (2018) realizou uma comparação estatística por meio de média em subáreas, para todo o território brasileiro. O autor encontrou, para a subárea sudeste, uma correlação de 0,86, RMSE de 3,93 e BIAS de 0,07. A subárea sudeste está localizada próximo a região da BHRS, e os valores estatísticos encontrados em ambos os estudos foram bem próximos.

4.6 Comparação entre as quatro análises

Realizando uma comparação entre os resultados médios encontrados para cada um dos quatro métodos (Tabela 11), nota-se que a média na área obteve os melhores valores. Entretanto, mesmo possuindo os melhores resultados estatísticos, por ser uma média simples acaba suavizando valores muito discrepantes nas séries de dados, não representando a realidade. Sendo assim, é mais viável a utilização dos outros métodos.

A metodologia que realizou uma correção de viés dos dados do GPM, pixel a ponto, apresentou resultados médios muito semelhantes aos resultados do método ponto a pixel. Já o método que interpola os dados da ANA, pixel a pixel, os resultados médios encontrados foram melhores do que para os dois métodos anteriores.

Comparando os resultados médios encontrados para o método ponto a pixel – série completa, verão e inverno; observa-se melhores valores para a estação de inverno. A correlação no inverno ficou bem próxima dos resultados que foram encontrados para o método pixel a pixel.

De modo geral, a metodologia pixel a pixel apresentou melhoras em relação a série completa do ponto a pixel, se mostrando um bom método de comparação entre os dados.

Tabela 11 – Valores médios das estatísticas para cada método aplicado no estudo

Métodos	ρ	R^2	MAE	RMSE	BIAS
Ponto a Pixel Série Completa	0.58	0.36	3.02	7.35	0.14
Verão	0.53	0.31	5.55	10.24	0.10
Inverno	0.64	0.46	0.87	3.18	0.05
Pixel a Ponto Série Completa	0.57	0.35	2.96	7.57	0.01
Pixel a Pixel Série Completa	0.63	0.40	2.82	6.72	0.11
Média na Área Série Completa	0.82	0.67	1.94	4.06	0.07

5 CONCLUSÃO

O principal objetivo do presente estudo foi de avaliar os dados diários de precipitação estimados pelo GPM para o produto IMERG – *final run*, em comparação com os dados registrados por pluviômetros em superfície. Essa comparação foi aplicada para diferentes métodos e realizada através de estatísticas, e foram apresentadas nas seções anteriores.

Através das análises dos resultados, concluiu-se que para a precipitação diária na BHRS e o seu entorno, pelo método ponto a pixel – série completa, o GPM apresentou uma baixa capacidade em caracterizar os eventos de precipitação na bacia, pois a sua maior taxa de acerto foi para os intervalos de precipitação de 0 e 1 mm dia⁻¹ (melhor resultado) e 10 e 50 mm dia⁻¹. De acordo com as estatísticas geradas para esse método, o GPM apresentou menores erros para a estação de inverno, que é um período mais seco. No verão, período chuvoso na região, os valores das estatísticas ficaram mais baixos, se comparados com o inverno, sendo assim, a capacidade de estimativa da precipitação pelo GPM é mais baixa para essa estação.

Para a série completa, os valores das estatísticas ficaram um pouco mais alta do que para o verão, porém não superaram os valores para o inverno. De modo geral, para todos os três casos, apontou-se uma correlação média moderada entre os dados, com erros variando da magnitude de 3 a 10 mm dia⁻¹ e com uma tendência média de superestimativa do GPM em relação aos dados da ANA. Para o método pixel a ponto, os resultados médios encontrados foram muito semelhantes aos da série completa do

ponto a pixel. Já os valores médios do método pixel a pixel ficaram um pouco melhores do que para os métodos anteriores. Quanto a média das três subáreas do método média na área, os resultados encontrados foram os melhores, pois encontrou-se uma correlação alta, coeficiente de determinação (R^2) acima de 60% e magnitude dos erros mais baixos. Analisando o valor médio do BIAS (Tabela 10) em todas as metodologias utilizadas, observa-se uma tendência de superestimativa do GPM.

Pelo método pixel a ponto, observou-se que a interpolação dos dados do GPM trouxe melhoras na frequência de precipitação, pois analisando as curvas de permanência antes e após essa interpolação, é notável essa melhora. Sendo assim, é viável a utilização dessa metodologia para aplicar correções nos estudos que levam em consideração a frequência de precipitação.

O método pixel a pixel, que realizou interpolações dos dados da ANA, se mostrou eficiente em aumentar a cobertura de dados em solo, pois através dessa interpolação, lugares onde não haviam estações passaram a ter dados, além disso, os valores estatísticos apresentaram uma leve melhora.

Como a precipitação é uma variável muito importante e pode ser utilizada em diferentes estudos, a utilização de dados provenientes de satélites é uma boa opção para aumentar a cobertura de dados, especialmente em áreas onde não existem estações pluviométricas disponíveis, como forma de auxiliar esses estudos. Como os resultados encontrados apresentaram a existência de falhas nos dados do satélite para a escala diária, além de uma tendência de superestimativa do GPM para os dados da ANA, sugere-se a aplicação dessa mesma metodologia para escalas de tempo maiores, ou ainda a criação de uma metodologia de correção para esses dados. Além disso, sugere-se a aplicação das estatísticas de contingência para outros intervalos de precipitação que consiga melhor caracterizar o padrão de chuva na região, uma vez que os intervalos aplicados não se apresentaram satisfatórios, como por exemplo o limiar de chuva extrema que recebeu um valor muito elevado para a área de estudo. Ainda se espera que esse estudo auxilie outros trabalhos que pretendem utilizar as estimativas de precipitação do GPM, especialmente para realizar comparações, pois é fornecido diversas metodologias de comparações com dados pluviométricos em solo.

6 REFERÊNCIAS

- ALMEIDA, L. T., ABREU, M. C., FRAGA, M. S., SILVA, D. D., CECÍLIO, R. A. Aspectos morfométricos relacionados ao estudo de enchentes na Bacia do Rio Sapucaí, Minas Gerais. **Nativa**, v. 5, n. 3, 2017.
- ALVES, K. S. da S., ALVES, A. V. P., SOUZA, N. S. E., SANCHES, L., GAIO, D. C., SOUZA, G. S., DE MUSIS, C. R. ANÁLISE ESTATÍSTICA ENTRE OS DADOS DE PRECIPITAÇÃO ESTIMADA VIA SATÉLITE TRMM E DADOS OBSERVADOS DE SUPERFÍCIE EM PRAIA - CABO VERDE. **Revista Brasileira de Climatologia**, v. 21, p. 417-429, 2017.
- AMBRIZZI, T., FERRAZ, S. E. T. An objective criterion for determining the South Atlantic Convergence Zone. **Frontiers in Environmental Science**, v. 3, p. 23, 2015.
- ANA - Agência Nacional de Águas. **Cartilha do observador - Pluviometria**. Brasília: ANA, 2ª ed., 2014. 12 p.
- ANDERS, A. M., ROE, G. H., HALLET, B., MONTGOMERY, D. R., FINNEGAN, N. J., PUTKONEN, J. Spatial patterns of precipitation and topography in the Himalaya. **Special Papers-Geological Society of America**, v. 398, p. 39, 2006.
- ASONG, Z. E., RAZAVI, S., WHEATER, H. S., WONG, J. S. Evaluation of Integrated Multisatellite Retrievals for GPM (IMERG) over Southern Canada against Ground Precipitation Observations: A Preliminary Assessment. **Journal of hydrometeorology**, v. 18, n. 4, p. 1033-1050, 2017.
- BARBOSA, A. A., OLIVEIRA, G. M., OLIVIERA, T. J. Histórico de enchentes em Itajubá/MG. **Revista Meio Ambiente e Sustentabilidade**, v. 9, n. 4, p. 125-140, 2015.
- BRAGA, R. S., CATALDI, M., OLIVEIRA, H. C. Metodologia para previsão de vazões na Bacia do Rio Grande. **XVIII Simpósio Brasileiro de Recursos Hídricos**, Campo Grande, 2009.
- CARVALHO, L. M. V., JONES, C., LIEBMANN, B. The South Atlantic Convergence Zone: Intensity, Form, Persistence, and Relationships with Intraseasonal to Interannual Activity and Extreme Rainfall. **Journal of Climate**, v. 17, n. 1, p. 88-108, 2004.

CONDOM, T., RAU, P., ESPINOZA, J. C. Correction of TRMM 3B43 monthly precipitation data over the mountainous areas of Peru during the period 1998–2007. **Hydrological Processes**, v. 25, n. 12, p. 1924-1933, 2011.

COPASA. **Companhia de Saneamento de Minas Gerais. Plano Diretor de Recursos Hídricos da Bacia Hidrográfica do Rio Sapucaí**. Resumo Executivo. Belo Horizonte: COPASA, 2010.

CORREA, S. M. B. B. (2^aed.). **Probabilidade e estatística**. Belo Horizonte: PUC Minas Virtual, 2003.

CRUZ, J. C., TUCCI, C. E. M. Estimativa da Disponibilidade Hídrica através da Curva de Permanência. **RBRH – Revista Brasileira de Recursos Hídricos**, v. 13, n. 1, p. 111-124, 2008.

FIGUEIREDO FILHO, D. B., SILVA JÚNIOR, J. A. Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r). **Revista Política Hoje**, v. 18, n. 1, 2009.

FREITAS, A. A., DRUMOND, A., CARVALHO, V. S. B., REBOITA, M. S., SILVA, B. C., UVO, C. B. Drought Assessment in São Francisco River Basin, Brazil: Characterization through SPI and Associated Anomalous Climate Patterns. **Atmosphere**, v. 13, n. 1, p. 41, 2022.

GADÊLHA, A. N. **Análise da Missão GPM (Global Precipitation Measurement) na estimativa da precipitação sobre Território Brasileiro**. 2018. Dissertação (Mestrado em Engenharia Civil e Ambiental) – Universidade Federal da Paraíba, Paraíba, 2018.

GPM. GLOBAL PRECIPITATION MEASUREMENT. **TRMM Comes to an End after 17 Years**. 2015. Disponível em: <<https://gpm.nasa.gov/missions/trmm/mission-end>>. Acesso em: 27 de outubro de 2020.

GPM. GLOBAL PRECIPITATION MEASUREMENT. **The Global Precipitation Measurement Mission (GPM)**. 2020a. Disponível em: <<https://gpm.nasa.gov/missions/GPM>>. Acesso em: 27 de outubro de 2020.

GPM. GLOBAL PRECIPITATION MEASUREMENT. **GPM Core Observatory**. 2020b. Disponível em: <<https://gpm.nasa.gov/missions/GPM/core-observatory>>. Acesso em: 28 de outubro de 2020.

GUIMARÃES, P. R. B. **Análise de Correlação e medidas de associação**. Disponível em: <<https://docs.ufpr.br/~jomarc/correlacao.pdf>>. Acesso em: 28 de outubro de 2020.

HASHEMI, H., NORDIN, M., LAKSHMI, V., HUFFMAN, G. J., KNIGHT, R. Bias Correction of Long-Term Satellite Monthly Precipitation Product (TRMM 3B43) over the Conterminous United States. **Journal Of Hydrometeorology**, v. 18, n. 9, p. 2491-2509, 2017.

HASHEMI, H., FAYNE, J., LAKSHMI, V., HUFFMAN, G. J. Very high resolution, altitude-corrected, TMPA-based monthly satellite precipitation product over the CONUS. **Scientific Data**, v. 7, n. 74, p. 1-10, 2020.

HE, ZHIHUA., YANG, L., TIAN, F., NI, G., HOU, A., LU, H. Intercomparisons of Rainfall Estimates from TRMM and GPM Multisatellite Products over the Upper Mekong River Basin. **Journal of Hydrometeorology**, v. 18, n. 2, p. 413-430, 2017.

HERDIES, D. L., SILVA, A. da., DIAS, M. A. F., FERREIRA, R. N. Moisture budget of the bimodal pattern of the summer circulation over South America. **Journal of Geophysical Research: Atmospheres**, v. 107, n. D20, p. LBA 42-1-LBA 42-10, 2002.

HOU, A. Y., KAKAR, R. K., NEECK, S., AZARBARZIN, A. A., KUMMEROW, C. D., OKI, R., NAKAMURA, K., IGUCHI, T. The Global Precipitation Measurement Mission. **Bulletin of the American Meteorological Society**, v. 95, n. 5, p. 701-722, 2014.

HUFFMAN, G. J., BOLVIN, D. T., BRAITHWAITE, D., HSU, K., JOYCE, R., KIDD, C., NELKIN, E. J., SOROOSHIAN, S., TAN, J., XIE, P. NASA Global Precipitation Measurement (GPM) Integrated Multi-satellitE Retrievals for GPM (IMERG). **Algorithm Theoretical Basis Document (ATBD) Version 06**, v. 4, p. 26, 2015.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Produto Interno Bruto dos Municípios**. 2019. Disponível em: <<https://www.ibge.gov.br/estatisticas/economicas/contas-nacionais/9088-produto-interno-bruto-dos-municipios.html>>. Acesso em: 15 de dezembro de 2021.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Estimativas da População**. 2021. Disponível em: <<https://www.ibge.gov.br/estatisticas/sociais/populacao/9103-estimativas-de-populacao.html>>. Acesso em: 15 de dezembro de 2021.

KIDD, C., HUFFMAN, G. Global precipitation measurement. **Meteorological Applications**, v. 18, n. 3, p. 334-353, 2011.

KODAMA, Y. Large-Scale Common Features of Subtropical Precipitation Zones (the Baiu frontal zone, the SPCZ, and the SACZ) Part I: Characteristics of Subtropical Frontal Zones. **Journal of the Meteorological Society of Japan**, v. 70, n. 4, p. 813-836, 1992.

KUMMEROW, C., SIMPSON, J., THIELE, O., BARNES, W., CHANG, A. T. C., STOCKER, E., ADLER, R. F., HOU, A., KAKAR, R., WENTZ, F., ASHCROFT, P., KOZU, T., HONG, Y., OKAMOTO, K., IGUCHI, T., KUROIWA, H., IM, E., HADDAD, Z., HUFFMAN, G., FERRIER, B., OLSON, W. S., ZIPSER, E., SMÍTH, E. A., WILHEIT, T. T., NORTH, G., KRISHNAMURTI, T., NAKAMURA, K. The status of the Tropical Rainfall Measuring Mission (TRMM) after Two Years in Orbit. **Journal of applied meteorology**, v. 39, n. 12, p. 1965-1982, 2000.

LELIS, L. C. S., BOSQUILIA, R. W. D., DUARTE, S. N. Assessment of Precipitation Data Generated by GPM and TRMM Satellites. **Revista Brasileira de Meteorologia**, v. 33, p. 153-163, 2018.

LOPES, M. K. C. **Estimativas de precipitação das imagens de satélites comparada a registros pluviométricos na sub-bacia do Rio Piancó-Paraíba**. 2020. Dissertação (Mestrado em Sistemas Agroindustriais) – Universidade Federal de Campina Grande, Paraíba, 2020.

LU, X., TANG, G., WANG, X., LIU, Y., JIA, L., XIE, G., LI, S., ZHANG, Y. Correcting GPM IMERG precipitation data over the Tianshan Mountains in China. **Journal of Hydrology**, v. 575, p. 1239-1252, 2019.

MEDEIROS-FEITOSA, J. R., OLIVEIRA, C. W. Estudo comparativo dos dados de precipitação do satélite TRMM e postos pluviométricos no estado do Ceará, Brasil. **Revista Geográfica de América Central**, n. 65, p. 239-262, 2020.

MELO, D. de C. D., XAVIER, A. C., BIANCHI, T., OLIVEIRA, P. T. S., SCANLON, B. R., LUCAS, M. C., WENDLAND, E. Performance evaluation of rainfall estimates by TRMM Multi-satellite Precipitation Analysis 3B42V6 and V7 over Brazil. **Journal of Geophysical Research: Atmospheres**, v. 120, n. 18, p. 9426-9436, 2015.

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

NASTOS, P. T., KAPSOMENAKIS, J., PHILANDRAS, K. M. Evaluation of the TRMM 3B43 gridded precipitation estimates over Greece. **Atmospheric Research**, v. 169, p. 497-514, 2016.

OMRANIAN, E., SHARIF, H. O. Evaluation of the Global Precipitation Measurement (GPM) satellite rainfall products over the lower Colorado River basin, Texas. **JAWRA Journal of the American Water Resources Association**, v. 54, n. 4, p. 882-898, 2018.

PASSOW, M. J. TRMM-Tropical Rainfall Measuring Mission: Bringing remote sensing of precipitation into your classroom. **Terræ Didática**, v. 6, n. 1, p. 03-08, 2010.

PEREIRA, G., SILVA, M. E. S., MORAES, E. C., CARDOZO, F. da S. Avaliação dos Dados de Precipitação Estimados pelo Satélite TRMM para o Brasil. **Revista Brasileira de Recursos Hídricos**, v. 18, n. 3, p. 139-148, 2013.

PETRUCCI, E. **Características do clima de Uberlândia-MG**: análise da temperatura, precipitação e umidade relativa. 2018. Dissertação (Mestrado em Geografia) – Universidade Federal de Uberlândia, Uberlândia, 2018.

PINHEIRO, M. V. **Avaliação Técnica e Histórica das Enchentes em Itajubá-MG**. 2005. Dissertação (Mestrado em Engenharia da Energia) – Universidade Federal de Itajubá, Itajubá, 2005.

QUADRO, M. F. L. de. Estudo de episódios de zonas de convergência do Atlântico Sul (ZCAS) sobre a América do Sul. **Revista Brasileira de Geofísica**, v. 17, n. 2-3, p. 210-210, 1999.

QUEDI, E. S., CAMPOS, J. A., FAN, F. M. Validação de dados do Global Precipitation Mission (GPM) com observações in situ na bacia do Rio São Francisco. *In*: Simpósio de Recursos Hídricos do Nordeste, 2018, Maceió, Alagoas. **Anais...** Porto Alegre: ABRHidro, 2018.

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

REBOITA, M. S., MARIETTO, D. M. G., SOUZA, A., BARBOSA, M. Caracterização atmosférica quando da ocorrência de eventos extremos de chuva na Região Sul de Minas Gerais. **Revista Brasileira de Climatologia**, v. 21, 2017.

REBOITA, M. S., da SILVA, B. C., da SILVA, M. V. Modelos de Regressão Aplicados à Previsão de Nível Fluviométrico no Rio Sapucaí em Itajubá-MG. **Anuário do Instituto de Geociências**, v. 42, n. 2, p. 217-229, 2019.

REIS, J. B. C. dos, 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. 12, p. 1240, 2017.

SÁ JÚNIOR, A., CARVALHO, L. G., SILVA, F. F., ALVES, M. C. Application of the Köppen classification for climatic zoning in the state of Minas Gerais, Brazil. **Theoretical and Applied Climatology**, v. 108, n. 1-2, p. 1-7, 2012.

SANTOS, R. S., COSTA, L. C., SEDIYAMA, G. C., LEAL, B. G., OLIVEIRA, R. A., JUSTINO, F. B. Avaliação da relação seca/produtividade agrícola em cenário de mudanças climáticas. **Revista Brasileira de Meteorologia**, v. 26, n. 2, p. 313-321, 2011.

SANTOS, S. R. Q. dos, SANSIGOLO, C. A., NEVES, T. T. de A. T., CAMPOS, T. L. de O. B., SANTOS, A. P. P. dos. Frequências dos eventos extremos de seca e chuva na Amazônia utilizando diferentes bancos de dados de precipitação. **Revista Brasileira de Geografia Física**, v. 10, n. 2, p. 468-478, 2017.

SANTOS, S. R. Q. dos, CUNHA, A. P. M. do, RIBEIRO-NETO, G. G. Avaliação de dados de precipitação para o monitoramento do padrão espaço-temporal da seca no Nordeste do Brasil. **Revista brasileira de climatologia**, v. 25, 2019.

SILVA, B. S. G., VALERIANO, D. de M. Correção atmosférica e topográfica de imagens de satélite em terrenos montanhosos. In: **XII Simpósio Brasileiro de Sensoriamento Remoto**. 2005. p. 3587-3594.

SILVA, A. C., BERG, E. V. D., HIGUCHI, P., NUNES, M. H. Dinâmica de uma comunidade arbórea após enchente em fragmentos florestais no sul de Minas Gerais. **Revista Árvore**, v. 35, n. 4, p. 883-893, 2011.

SILVA, P. do N., CAPUCIN, B. C., SILVA, B. A., REBOITA, M. S. Características Anômalas do Verão de 2019. **Revista Brasileira de Climatologia**, v. 27, 2020.

SILVA, P. do N., ESCOBAR, G. C. J., REBOITA, M. S. Eventos extremos de precipitação no Estado de Minas Gerais associados com a ocorrência de episódios de Zona de Convergência do Atlântico Sul. **Revista Brasileira de Geografia Física**, v. 13, n. 3, p. 1013-1023, 2020.

SOARES, A. S. D., PAZ, A. R. da, PICCILLI, D. G. A. Avaliação das estimativas de chuva do satélite TRMM no Estado da Paraíba. **RBRH**, v. 21, p. 288-299, 2016.

TEODORO, T. A., PASSOS, R. B., SILVA, B. A., SILVA, B. C. Análise das Estimativas da Precipitação Diária do Produto GPM-IMERG na Bacia Hidrográfica do Rio Sapucaí, Região Sudeste do Brasil. **Anuário do Instituto de Geociências**, v. 43, n. 2, 2020.

TORRES, F. L. R., FERREIRA, G. W. de S., KUKI, C. A. C., VASCONCELLOS, B. T. C., FREITAS, A. A., SILVA, P. do N., SOUZA, C. A., REBOITA, M. S. VALIDAÇÃO DE DIFERENTES BASES DE DADOS DE PRECIPITAÇÃO NAS BACIAS HIDROGRÁFICAS DO SAPUCAÍ E SÃO FRANCISCO. **Revista Brasileira de Climatologia**, v. 27, 2020.

TWARDOSZ, R., CEBULSKA, M., WALANUS, A. Anomalously heavy monthly and seasonal precipitation in the Polish Carpathian Mountains and their foreland during the years 1881–2010. **Theoretical and Applied Climatology**, v. 126, n. 1-2, p. 323-337, 2016.

VERA, C., HIGGINS, W., AMADOR, J., AMBRIZZI, T., GARREAU, R., GOCHIS, D., GUTZLER, D., LETTENMAIER, D., MARENGO, J., MECHOSO, C. R., NOGUES-PAEGLE, DIAS, P. L. S., ZHANG, C. Toward a unified view of the American monsoon systems. **Journal of climate**, v. 19, n. 20, p. 4977-5000, 2006.

VIANA, D. R., FERREIRA, N. J., CONFORTE, J. C. Avaliação das estimativas de precipitação 3B42 e 3B43 do satélite TRMM na Região Sul do Brasil. *In: Congresso Brasileiro de Meteorologia*. 2010.

WILKS, D. S. **Statistical methods in the atmospheric sciences**. Academic press, 2011.

YUAN, F., ZHANG, L., WIN, K. W. W., REN, L., ZHAO, C., ZHU, Y., JIANG, S., LIU, Y. Assessment of GPM and TRMM Multi-Satellite Precipitation Products in Streamflow Simulations in a Data-Sparse Mountainous Watershed in Myanmar. **Remote Sensing**, v. 9, n. 3, p. 302, 2017.

ZUBIETA, R., GETIRANA, A., ESPINOZA, J. C., LAVADO-CASIMIRO, W., ARAGON, L. Hydrological modeling of the Peruvian–Ecuadorian Amazon Basin using GPM-IMERG satellite-based precipitation dataset. **Hydrology and Earth System Sciences**, v. 21, n. 7, p. 3543-3555, 2017.