



ISSN:1984-2295

Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



Análise comparativa entre os dados de precipitação do programa GPM e os observados por estações meteorológicas em Sergipe

Glauber Vinícius Pinto de Barros¹, Rosemeri Melo e Souza², Felipe Souza dos Santos³

¹ Doutorando em Geografia, Universidade Federal de Sergipe, São Cristóvão, Av. Governador Marcelo Deda Chagas, s/n, CEP 49100-000 glauber.barros@hotmail.com, ORCID: 0000-0002-8324-1402. ² Professora Doutora, Universidade Federal de Sergipe, São Cristóvão, Av. Governador Marcelo Deda Chagas, s/n, CEP 49100-000, rome@academico.ufs.br, ORCID: 0000-0002-5916-3598. ³ Doutorando em Meteorologia, Instituto Nacional de Pesquisas Espaciais, Cachoeira Paulista, Rodovia Presidente Dutra, s/n, CEP 12630-000, felipe.santos@inpe.br, ORCID: 0000-0002-7114-5448.

Artigo recebido em 23/2/2024 e aceito em 03/02/2025

RESUMO

A disponibilidade de dados precisos de precipitação é essencial para estudos climatológicos e hidrológicos. No entanto, a escassez de estações meteorológicas bem distribuídas limita a precisão dessas análises. Diante desse desafio, os dados de precipitação estimados por satélites, como os do programa Global Precipitation Measurement (GPM), têm sido amplamente utilizados. Este estudo avalia a capacidade do produto GPM-IMERG de representar as precipitações no estado de Sergipe, comparando os dados estimados com os observados em estações meteorológicas do INMET e ANA. Foram analisados dados de precipitação mensal acumulada entre 2010 e 2020, utilizando coeficiente de correlação de Pearson, coeficiente de determinação, erro médio absoluto, raiz do erro médio quadrático (REMQU) e coeficiente de concordância de Willmott. Os resultados indicam correlações moderadas a fortes ($r > 0,70$), com boa concordância espacial das médias anuais. No entanto, foi identificada uma tendência do GPM-IMERG à subestimação dos valores de precipitação, especialmente em áreas litorâneas e em períodos de maior pluviosidade. Apesar dessa limitação, os dados de satélite foram capazes de acompanhar as variações sazonais para os diferentes tipos climáticos que ocorrem no estado, além de mostrarem potencial para complementar redes meteorológicas, especialmente em regiões semiáridas. Assim, o GPM-IMERG pode ser uma ferramenta valiosa para estudos hidrológicos e planejamento de recursos hídricos em Sergipe. Palavras-chave: Clima, Sensoriamento remoto, Estatística, Interpolação.

Statistical evaluation of the precipitation estimates of the GPM program and the data observed by meteorological stations in Sergipe

ABSTRACT

The availability of accurate precipitation data is essential for climatological and hydrological studies. However, the scarcity of well-distributed meteorological stations limits the precision of such analyses. To address this challenge, satellite-derived precipitation data, such as those from the Global Precipitation Measurement (GPM) program, have been widely used. This study evaluates the ability of the GPM-IMERG product to represent precipitation in the state of Sergipe, comparing satellite estimates with observations from INMET and ANA meteorological stations. Monthly accumulated precipitation data from 2010 to 2020 were analyzed using Pearson's correlation coefficient, the coefficient of determination, mean absolute error, root mean square error (RMSE), and Willmott's concordance index. The results indicate moderate to strong correlations ($r > 0.70$), with good spatial agreement of annual precipitation averages. However, GPM-IMERG showed a tendency to underestimate precipitation values, particularly in coastal areas and during periods of higher rainfall. Despite this limitation, satellite-derived data were able to track the seasonal variations for the different climate types occurring in the state, as well as demonstrated potential to complement meteorological networks, especially in semi-arid regions. Thus, GPM-IMERG can be a valuable tool for hydrological studies and water resource planning in Sergipe.

Keywords: Climate, Remote sensing, Statistic, Interpolation.

Introdução

O conhecimento da precipitação, bem como os diversos parâmetros que podem ser aferidos a partir de sua quantificação, tem importância fundamental

para a caracterização climatológica e ambiental de uma região. Para Yu et al. (2021) os dados de precipitação são cruciais, devido sua utilização

para a previsão de condições extremas, eventos de inundação, simulações hidrológicas, estimar vazão para gestão de reservatórios de barragens e operação de sistemas de abastecimento de água, emissão alertas de deslizamentos de terra e fornecer informações para modelos de irrigação, especialmente em regiões de clima semiárido.

Esta crucialidade dos dados de precipitação acaba sendo expressa pela numerosa quantidade de trabalhos que investigam tanto o comportamento espaço-temporal das chuvas, como as novas e diferentes formas de mensurar e descrever os dados de precipitação e suas características, em diversas partes do Brasil e do mundo (Fan et al. 2021; Moraux et al. 2021; Borges et al. 2021; Tercini et al. 2024; Junior et al. (2021).

Estes estudos só foram possíveis pois utilizaram de uma vasta quantidade de dados observados. No entanto, não é sempre que regiões que necessitam ser estudadas dispõem de redes de estações meteorológicas distribuídas de forma satisfatória, ou até mesmo com quantidade de dados consolidados suficiente para possibilitar o desenvolvimento de estudos climatológicos. Segundo Zhang e Wang (2023), a qualidade dos dados meteorológicos depende da densidade da rede de medição e da escala de observação, sendo comum que em regiões com baixa densidade da rede de monitoramento seja limitada a precisão dos estudos sinóticos e climatológicos.

Logo, a baixa disponibilidade de dados pluviométricos consistentes e bem distribuídos espacialmente, capazes de compor séries históricas completas, é uma das maiores dificuldades encontradas durante a realização de estudos meteorológicos e climatológicos.

Diante disto, uma das opções que tem sido utilizada em diversos estudos, são os dados oriundos de sensores a bordo de satélites, como os que fazem parte de projetos como Climate Hazards group InfraRed Precipitation with Station data (CHIRPS), Tropical Rainfall Measuring Mission (TRMM), Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks (PERSIANN) e Global Precipitation Measurement (GPM) (Miri et al. 2019, Tang et al. 2020, Le et al. 2020, Jiang et al. 2021).

Esses estudos chegaram a um denominador comum, que aponta para a eficiência satisfatória dos dados de precipitação obtidos por satélite, principalmente nas escalas diária e mensal, tendo como principal limitação áreas de topografia bastante acidentada e climas frios.

Para Kawo et al. (2021), produtos de precipitação estimados por satélite tem potencial significativo de uso em áreas com redes de estações de monitoramento pluviométrico limitadas, sendo

possível utilizar os dados destes produtos para investigar a variabilidade da precipitação e seus efeitos na disponibilidade de recursos hídricos.

Os produtos estimados por satélite, ao longo dos últimos anos tem apresentado cada vez mais uso para representar a precipitação em áreas sem estações meteorológicas ou para o preenchimento de falhas dos dados de estações. Durante os últimos trinta anos os dados de satélite se tornaram uma fonte promissora de estimativa de precipitação em escala global (Levizzani e Cattani, 2019). Wang et al. (2020) afirmam que os satélites dotados de sensores que captam a informação de energia no espectro infravermelho, usam esta informação para estimar a precipitação com base na radiação infravermelha do topo das nuvens.

Contudo, mesmo com um potencial para diferentes aplicações, Khodadoust et al. (2017) ressaltam que os dados estimados por satélites estão sujeitos a incertezas devido a fatores como a refletância do topo das nuvens, radiação térmica e falhas no algoritmo de estimativa dos valores de precipitação e ainda devido a fatores topográficos, como indica Kawo et al. (2021). Para Dembélé e Zwart (2016), uma validação minuciosa dos dados de precipitação estimados por satélite, para qualquer área, é necessária para que se possa atingir um entendimento a respeito da acurácia destes dados, bem como identificar erros e suas origens, podendo assim incrementar os algoritmos e sensores utilizados nos programas de medição da precipitação por satélite. Ainda sobre a acurácia dos dados, Mondal et al. (2018), resalta que a avaliação da acurácia dos dados é fator imperativo antes da utilização deles em modelos hidrológicos.

Dentre os produtos de sensoriamento remoto, o GPM vem sendo estudado por diversos trabalhos acerca de sua eficiência em representar a precipitação e o clima quando comparados a estações meteorológicas em terra.

De acordo com Hou et al. (2014), o programa GPM, escolhido como fonte dos dados estimados para este trabalho, foi lançado em 2014 devido ao grande sucesso do TRMM. Sendo assim, a Administração Nacional da Aeronáutica e do Espaço dos Estados Unidos (NASA) juntamente a Agência Exploratória Aeroespacial do Japão (JAXA), realizaram a missão de lançamento do GPM. Segundo Maghsood et al. (2019), o algoritmo que processa os dados obtidos pelos satélites do GPM, o Integrated Multi-satellite Retrievals for GPM (IMERG), foi baseado nas experiências obtidas com a TRMM, possuindo uma resolução espaço temporal e cobertura além da qual possuía o seu antecessor.

Desde seu lançamento, diversos trabalhos têm sido elaborados usando os dados do GPM com

diferentes objetivos. Pradhan et al. (2022) conduziram um estudo, que consistiu numa revisão sistemática de literatura técnica para avaliar a performance dos dados obtidos pelo IMERG em diversas partes do mundo, com diferentes condições climáticas, identificando que grande parte dos estudos foram elaborados avaliando o comportamento dos dados para a Ásia, em particular a China.

Dentre as formas como estes estudos se apresentam, existem aqueles que se propõem a comparar estatisticamente o comportamento do produto do GPM com as medições realizadas por estações pluviométricas e meteorológicas.

Duarte et al. (2021) avaliaram as estimativas de precipitações diárias, mensais e anuais do GPM obtidas a partir do IMERG para região centro-oeste do Brasil, em comparação com os dados observados por estações meteorológicas da Agência Nacional de Águas (ANA) e concluíram que os dados do GPM possuem um desempenho relativamente bom em escala diária para regiões com topografia suave, sendo capaz de descrever o regime de chuvas em escalas de tempo maiores, independentemente das condições do terreno.

Teodoro et al. (2020), que analisaram as estimativas de chuva do produto diário do GPM-IMERG em relação aos dados das estações pluviométricas da ANA para a Bacia Hidrográfica do Rio Sapucaí, região Sudeste do Brasil e identificaram que o IMERG possui dificuldades em estimar a precipitação diária na bacia em questão, durante os meses de verão.

Nascimento et al. (2021), compararam os dados do IMERG com os dados de estações meteorológicas no estado do Paraná, no sul do Brasil, e concluíram que de modo geral, os dados apresentaram um desempenho positivo na estimativa de eventos de chuva mensais, tanto em volume quanto na distribuição espacial, e demonstraram desempenho limitado para eventos diários e anomalias, principalmente em regiões montanhosas (costa e sudoeste).

Há ainda aqueles estudos que objetivam comparar os resultados do GPM-IMERG em relação a outros programas, quando comparados a dados observados. Fang et al (2019), ao avaliarem os dados estimados pelo TRMM e pelo GPM com os dados observados por estações da China Meteorological Administration (CMA), identificaram que o GPM obteve uma performance melhor do que o TRMM. Segundo os autores supracitados, a performance foi melhor para o sul da China, que possui o clima úmido de monções, do que para o clima árido de altitude do oeste chinês, indicando uma influência significativa da topografia sob o clima.

Peng et al. (2020) compararam a capacidade de detecção de precipitação de produtos como GPM-IMERG, TRMM 3B42, PERSIANN e CHIRPS em uma região agrícola da China, com o GPM-IMERG se destacando com a melhor capacidade de detecção de precipitação em todas as escalas temporais (diária, sazonal e anual), enquanto os outros produtos apresentaram desempenho inferior, especialmente durante o verão, quando a precipitação é mais intensa.

Jiang et al. (2021), compararam a eficiência dos dados obtidos pelo TRMM, GPM IMERG, PERSIANN e CHIRPS, com dados medidos por pluviômetros no sudoeste da China, concluindo que o GPM IMERG e o CHIRPS são os mais precisos em diferentes bacias hidrográficas e em altitudes superiores a 4000 metros, enquanto os outros produtos mostraram desempenho inferior, especialmente em áreas de baixa altitude.

Arshad et al. (2021), avaliaram os produtos de estimativa de precipitação do GPM-IMERG e do TRMM-3B42 em comparação com os dados medidos por estações pluviométricas entre os anos de 2004 e 2018 para o Paquistão. O GPM-IMERG apresentou desempenho acima do TRMM-3B42, no entanto, no inverno e no período pré-monções, os dados do GPM-IMERG captaram de forma superestimada os valores de precipitação no nordeste da área de estudo.

Vázquez-Rodríguez et al. (2024), avaliaram a precisão dos dados de precipitação de produtos GPM-IMERG e PERSIANN CCS na Bacia Rio Grande-San Juan, no nordeste do México. Os autores concluíram que o GPM-IMERG teve uma melhor performance em relação as estimativas mensais, obtendo melhora caracterização estatística que o PERSIANN. No entanto, para as estimativas anuais, o GPM acabou subestimando demasiadamente os dados, apesar de ter sido mais eficiente que o PERSIANN.

Esses estudos indicam que para a maioria das áreas avaliadas o GPM possui uma capacidade satisfatória de representar a precipitação principalmente em escala mensal e dentro de uma série temporal ampla, mostrando-se superior a outros programas, com uma limitação marcada por resultados menos expressivos em locais de terreno acidentado, clima frio e precipitações anômalas. Posto isto, é cabível o seguinte questionamento: Seria o GPM capaz de representar satisfatoriamente a precipitação no território do estado de Sergipe, o qual possui clima tropical em grande parte de seu território e ausência de sistemas orográficos de chuva? A resposta positiva a essa pergunta é a hipótese aqui levantada.

Este trabalho se justifica ainda no fato de que, em Sergipe, dados obtidos em superfície terrestre

por estações pluviométricas ou meteorológicas, são escassos, mesmo o estado possuindo estações relativamente bem distribuídas em seu território. Quando da elaboração deste trabalho, INMET, fonte de dados de precipitação consultada, possuía sete estações automáticas e duas estações convencionais em operação em solo sergipano. Já a ANA possuía em seu sistema Hidroweb um total de cinquenta e duas estações pluviométricas distribuídas por Sergipe. No entanto, a maioria destas se encontram com as medições descontinuadas e defasadas.

Sendo assim, o objetivo deste trabalho é de verificar se os dados estimados pelo programa GPM-IMERG conseguem representar as variações do clima nas diferentes regiões de Sergipe, a partir da realização de uma análise estatística comparativa entre as séries de dados de precipitação mensal acumulada estimadas por satélite, com os dados de precipitação mensal acumulada observadas nas estações meteorológicas do INMET e ANA. Para isso dentre os objetivos específicos estão: avaliar parâmetros estatísticos como coeficiente de correlação de Pearson, coeficiente de determinação, erro médio absoluto (EMA), raiz do erro médio quadrático

(REMQ) e coeficiente de concordância de Willmott para os dois conjuntos de dados (observados e estimados); além de realizar interpolação espacial das precipitações médias anuais e avaliar o comportamento da distribuição espacial dos dados em relação ao território sergipano.

Material e métodos

Área de estudo

O estado de Sergipe está localizado no Nordeste do Brasil, mantendo fronteiras à Norte com Alagoas, ao Sul e Oeste com a Bahia e a Leste com o oceano atlântico. De acordo com o IBGE (2024), Sergipe possui uma população estimada, para o ano de 2021, em 2.338.474 habitantes e uma extensão territorial de 21.938,188 km², fazendo com que o estado seja o menor da Federação. A Figura 1 apresenta a localização do estado de Sergipe e das estações meteorológicas cujos dados serviram de base para este trabalho.




Figura 1. Localização das estações meteorológicas em relação ao território sergipano.

Fonte: Elaborado a partir dos dados do IBGE (2024) e do SRTM (2000).

Segundo o sistema de classificação climática de Köppen (1936), adotado pelo Instituto Brasileiro de Geografia e Estatística (IBGE), o

estado de Sergipe possui majoritariamente duas regiões climáticas. A primeira é caracterizada como tropical de verões secos (As), com

temperaturas médias superiores a 18°C e precipitações médias anuais superiores aos 800 mm. Essa região engloba principalmente os municípios da costa litorânea do estado. A segunda região é a de clima semiárido (BSH), que ocorre na porção interiorana do estado. Esta segunda região é marcada por chuvas médias anuais entre 200 e 750 mm, distribuída em poucos meses do ano.

Procedimentos metodológicos

A aquisição dos dados de precipitação correspondentes ao estado de Sergipe, foi realizada em duas diferentes plataformas disponíveis na internet. Os dados de superfície, ou dados observados, foram adquiridos a partir do Banco de Dados Meteorológicos para Ensino e Pesquisa (<https://bdmep.inmet.gov.br/>) do INMET (2024), e do portal Hidroweb (<https://www.snirh.gov.br/hidroweb/apresentacao>) ANA (2024). Nas duas plataformas é possível obter os valores de diversas variáveis atmosféricas, como precipitação total, temperaturas mínimas, média e máximas e velocidade média do vento, medidas por

estações meteorológicas em diversos municípios brasileiros, para um determinado intervalo de tempo de interesse. No entanto, foram selecionados apenas os dados de precipitação mensal acumulada, para as estações meteorológicas automáticas dentro do território sergipano, com exceção da estação A371 (Piranhas-AL), escolhida para representar a região noroeste de Sergipe. Isto foi feito, uma vez que Piranhas está localizada no estado de Alagoas, porém, a pouco mais de dois quilômetros de Sergipe, logo, também está inserida no tipo climático tropical de verões secos (As), bem como a região que se deseja representar.

O intervalo de tempo adotado, foi selecionado para coincidir com a disponibilidade das séries de medições de dados do GPM-IMERG, disponíveis em Sergipe (Quadro 1).

A aquisição dos dados foi realizada no formato *comma separated value* (CSV), formato este que pode ser usado para trabalhar em softwares de planilha eletrônica, onde foram organizadas planilhas para cada estação, contendo uma coluna com as datas e outra com os respectivos valores de precipitação mensal acumulada

Quadro 1. Estações meteorológicas utilizadas no estudo.

Município	Código da estação	Latitude	Longitude	Série
Aracaju	A409	-10,9525	-37,0544	2010-2020
Itabaianinha	A417	-11,2725	-37,7950	2010-2020
Poço Verde	A419	-10,7380	-38,1083	2010-2020
Carira	A420	-10,3997	-37,7474	2010-2020
Brejo Grande	A421	-10,4738	-36,4819	2010-2020
Santa Rosa de Lima	1037049	-10,6471	-37,1933	2010-2020
Piranhas	A371	-9,6130	-37,7618	2010-2020

Fonte: Adaptado de INMET, 2024 e ANA, 2023

Os dados do GPM, gerados por meio de seu algoritmo IMERG, foram adquiridos a partir do portal Giovanni (<https://giovanni.gsfc.nasa.gov/giovanni/>) da National Aeronautics and Space Administration (NASA). Este portal é uma ferramenta desenvolvida para proporcionar uma maneira simples e intuitiva de visualizar, analisar e acessar dados de sensoriamento remoto da Terra, em diversas escalas temporais e espaciais de dados, principalmente os obtidos a partir de satélites.

Os dados de precipitação mensal acumulada (mm/mês) do IMERG foram adquiridos no formato matricial (raster), com resolução espacial de 0,1° x 0,1°, onde cada pixel possui um valor atribuído de precipitação mensal acumulada.

Foi realizado o download de um arquivo raster para cada um dos meses dos anos correspondentes à série adotada. Após adquiridos, através do software QGIS 3.16, os dados foram reprojados para o Sistema de Referência de Coordenadas

SIRGAS 2000, em seguida, por meio do comando Raster Values to Points, os valores dos pixels cujas posições continham as coordenadas das estações meteorológicas adotadas foram extraídos e transformados num arquivo vetorial, do tipo ponto, no formato shapefile.

Este processo permitiu a coleta dos valores acumulados mensais de precipitação, de modo a organizá-los na mesma planilha eletrônica produzida previamente para os dados observados, tendo como variável comum a data, neste caso o mês e ano que representavam.

O fluxograma presente na Figura 2, traz os processos realizados até a obtenção dos dados numa única tabela, a partir da qual as variáveis estatísticas foram calculadas, além da interpolação pelo inverso da distância ao quadrado e por krigagem, a fim de obter a distribuição espacial das precipitações médias anuais variáveis possibilitando uma análise da viabilidade do uso

dos dados obtidos pelo IMERG para regiões onde não haja estações meteorológicas.

A análise estatística aplicada para a comparação entre os valores de precipitação extraídos dos pixels dos arquivos raster do IMERG e dos valores observados, foi realizada a partir do cálculo do coeficiente de correlação (r), coeficiente de determinação (r^2), índice de concordância de Willmott (d), Erro Médio (EM) e Raiz do Erro Médio Quadrático (REMQ).




Figura 2. Fluxograma de etapas metodológicas

O coeficiente de correlação expressa a associação linear entre os valores extraídos do GPM e os valores observados pelas estações meteorológicas. De acordo com Figueredo Filho et al. (2014), o coeficiente de correlação de Pearson (r), varia entre -1 e 1. O sinal indica a direção da correlação (negativa ou positiva) enquanto o valor indica a magnitude. Quanto mais perto de 1 mais forte é o nível de associação linear entre as variáveis. Quanto mais perto de zero, menor é o nível de associação. Segundo Araújo et al. (2022), o cálculo de (r) se dá por meio da Equação 1, onde x_i são os dados da primeira variável, neste caso os dados do INMET e ANA; y_i os dados da segunda variável, estimados pelo IMERG; $\bar{x}$, é média dos dados observados; $\bar{y}$, é média dos dados estimados; e n o número de dados da série.

$$\text{Equação 1: } r = \frac{\sum_1^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum_1^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_1^n (y_i - \bar{y})^2}}$$

O coeficiente de determinação (r^2), é o quadrado do coeficiente de correlação (r) e é comumente usado para representar a proporção de variação da variável dependente que é explicada pela variação da variável independente. O (r^2) exercerá esse papel de modo significativo no caso de relações lineares estimadas pelo método dos mínimos quadrados ordinários. De acordo Araújo et al. (2022), o cálculo de (r^2) se dá por meio da Equação 2, onde x_i são os dados observados; y_i os dados estimados; $\bar{x}$, é média dos dados observados; $\bar{y}$, é média dos dados estimados; e n o número de dados da série.

$$\text{Equação 2: } r^2 = \frac{(\sum_1^n (x_i - \bar{x}) \cdot (y_i - \bar{y}))^2}{\sum_1^n (x_i - \bar{x})^2 \sum_1^n (y_i - \bar{y})^2}$$

Para avaliar a significância estatística entre os dados observados e estimados, foi realizado um teste t para os valores de cada estação e suas respectivas estimativas do IMERG. Segundo Mishra et al. (2019), o teste t de Student, é usado para comparar as médias entre dois grupos de dados e não há necessidade de comparações múltiplas, pois o valor P único é observado.

O índice de concordância de Willmott (d), foi utilizado para avaliar a concordância entre os valores observados e estimados. De acordo com Willmott et al. (1985), o índice de concordância é uma medida descritiva que reflete a precisão entre variáveis estimadas e observadas, sendo facilmente interpretado e aplicado independentemente das unidades de medida das variáveis. O índice varia entre 0 e 1 e assume valores próximos de 1 para concordâncias maiores e próximos a 0 para concordâncias menores. Os valores absolutos 0 e 1 representam respectivamente nenhuma concordância e concordância perfeita. Ainda segundo Willmott et al. (2012) o índice de concordância (d) pode ser expresso pela Equação (3):

$$\text{Equação 3: } d = 1 - \frac{\sum_1^n (y_i - x_i)^2}{\sum_1^n (|y_i - \bar{x}| + |x_i - \bar{y}|)^2}$$

Em que x_i é o valor observado, y_i o valor estimado e $\bar{x}$ e $\bar{y}$ são respectivamente as médias para os valores observados e estimados.

A fim de se observar tendências no comportamento dos valores de precipitação, foi gerado o Erro Médio (EM) que expressa a diferença média entre os volumes de chuva estimados e os valores observados nas estações meteorológicas, em milímetros (mm). O EM é uma medida de tendência, indicando a possível tendência de os dados estimados superestimar ($EM > 0$) ou subestimar ($EM < 0$) os dados de

precipitação observados. O Erro Médio pode ser obtido a partir da Equação (4).

$$\text{Equação 4: } EM = \frac{1}{n} \sum_{i=1}^n (y_i - x_i)$$

Para avaliar a precisão e a acurácia dos valores estimados pelo IMERG em relação aos dados observados, calculou-se a Raiz do Erro Médio Quadrático (REMQ), o qual resultado é expresso na mesma dimensão da variável, no caso, em milímetros por mês (mm/mês). De acordo com Vázquez-Rodríguez et al. (2024), o valor perfeito para REMQ é zero, sendo este parâmetro mais sensível a presença de erros significativos e valores discrepantes (outliers) nas estimativas de precipitação. Valores próximos a zero indicam que os valores extraídos do IMERG são muito próximos aos observados. Segundo Cruz et al. (2017), a REMQ pode ser calculada por meio da Equação (5):

$$\text{Equação 5: } REMQ = \sqrt{\frac{\sum_{i=1}^n (y_i - x_i)^2}{n}}$$

Com o objetivo de espacializar os resultados das precipitações médias anuais, as quais serão calculadas a partir das médias mensais para o intervalo de tempo estudado, utilizaram-se dois métodos de interpolação disponíveis no software QGIS 3.16. O primeiro foi o Inverso da Distância Ponderada, do inglês Inverse Distance Weighting (IDW), com o expoente λ_i da equação igual a 2. De acordo com Tuo, et al. (2016), inúmeros métodos foram desenvolvidos no passado para especializar dados de precipitação. Entre eles, o IDW e a krigagem e suas diversas variações. Com tudo, ainda segundo os autores supracitados, o IDW apresenta uma robustez e simplicidade que ainda o torna atrativo, sendo provavelmente o interpolador mais utilizado.

O IDW calcula o valor de um ponto-alvo considerando os valores dos pontos vizinhos, atribuindo maior peso àqueles que estão mais próximos do ponto-alvo. Para isso, o IDW utiliza as coordenadas cartesianas do ponto de interesse e aplica o inverso da distância, elevado a uma potência, que serve como fator de ponderação para os valores dos pontos ao redor (Sahu e Ghosh, 2021, Brindha, et al. 2023).

De acordo com Liu et al. (2019), o IDW é um dos métodos comumente usados em modelos determinísticos, e seu cálculo e precisão são afetados basicamente por dois fatores, raio de busca e o expoente de ponderação. Para o estudo em questão, o IDW será utilizado para estimar valores desconhecidos de precipitação com base na média ponderada dos valores observados mais próximos a partir da Equação (7) e Equação (8):

$$\text{Equação 7: } Z_{(x_0)} = \sum_{i=1}^n \lambda_i \cdot Z_{(x_i)}$$

$$\text{Equação 8: } \lambda_i = \frac{|d_{oi}|^{-d}}{\sum_{i=1}^n |d_{oi}|^{-d}}, d > 0$$

Em que $Z_{(x_0)}$ representa os valores de precipitação no ponto desconhecido, $Z_{(x_i)}$ os valores nos pontos conhecidos, ou seja, no local das estações meteorológicas, λ_i é o peso com o qual $Z_{(x_0)}$ será ponderado $d_{(oi)}$ é a distância entre o ponto desconhecido e a localização da estação meteorológica (i); o parâmetro d foi considerado igual a 2, como remendam Ly et al. (2011).

Por sua vez, a krigagem ordinária, considera a dependência espacial dos dados, utilizando um variograma para modelar essa dependência, o que permite atribuir pesos para a interpolação de forma otimizada. De acordo com Mahdi et al (2020), o variograma é uma ferramenta matemática fundamental na geoestatística, usado para medir como os dados se tornam mais diferentes uns dos outros à medida que a distância entre eles aumenta. A modelagem do variograma é crucial para determinar a precisão da krigagem, uma vez que a forma do variograma influencia diretamente os pesos atribuídos aos dados conhecidos para estimar valores desconhecidos.

Para o cálculo do variograma e da krigagem ordinária, utilizou-se as equações 9 e 10 conforme Lima et al. (2020)

$$\text{Equação 9. } \gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(X_i) - Z(X_i + h)]^2$$

$$\text{Equação 10: } Z^*(x_0) = \sum_{i=1}^N \lambda_i Z(X_i)$$

Em que $N(h)$ equivale ao número de pares de dados observados $Z(X_i)$ e $Z(X_i+h)$ equivahe ao um par a uma distância regular h de $Z(X_i)$. Já z^* indica o valor a ser estimado no ponto não amostrado x_0 . N se refere ao número de valores medidos $Z(X_i)$ envolvidos na estimativa e λ_i é o peso associado a cada valor medido $Z(X_i)$.

No software QGIS 3.16, a partir do plugin Smart Map, desenvolvido por Pereira et al. (2022), foi possível realizar o ajuste do variograma através do controle dos valores mais eficientes dos parâmetros: efeito pepita (Co), patamar (C+ Co), alcance (a) e coeficiente de determinação (R^2).

Resultados e discussão

De modo geral, a distribuição temporal da precipitação para as localidades avaliadas, apresentou similaridade entre as estimativas do GPM e os dados observados. O GPM se mostrou capaz de acompanhar de forma satisfatória a

variabilidade sazonal (Figura 3) dos períodos chuvosos e de estiagem para a região estudada. No entanto, é possível observar uma subestimação dos valores encontrados pelo produto de sensoriamento remoto do GPM-IMERG, principalmente em

relação ao potencial de acompanhar os picos mensais de chuva, como pode ser evidenciado para cada uma das localidades avaliadas e dispostas na Figura 3.




Figura 3. Precipitação mensal (mm) de 2010 a 2020 para Aracaju, Itabaianinha, Poço Verde, Carira e Brejo Grande, Santa Rosa de Lima e Piranhas, comparação entre GPM e dados observados do INMET e ANA para os municípios avaliados.

A partir dos resultados obtidos para as variáveis estatísticas (Tabela 1), é possível observar que os dados estimados do GPM e os

observados pelas estações meteorológicas, possuem alta correlação e significância para todos os municípios avaliados.

Tabela 1. Resultados dos valores de coeficiente de correlação (r), coeficientes de determinação, Erro Médio, Raiz do Erro Médio Quadrático e índice de concordância de Willmott entre os dados observados e estimados.

	Aracaju	Itabaianinha	Poço Verde	Carira	Brejo Grande	Sta. Rosa de Lima	Piranhas
r	0,85	0,90	0,73	0,83	0,90	0,83	0,83
r²	0,72	0,80	0,53	0,68	0,80	0,69	0,69
EM	-39,17	-23,44	-5,30	-1,05	-16,88	-32,27	8,98
REMQ	62,37	41,38	29,77	26,58	47,67	61,37	27,25
d	0,84	0,88	0,83	0,90	0,91	0,82	0,89

Os valores obtidos para o coeficiente de correlação variam entre 0,75 para Poço Verde e 0,90 para Itabaianinha e Brejo Grande. Estes valores se caracterizam por denotar uma correlação fortemente linear e positiva entre os dois conjuntos de dados, o que permite afirmar que os valores estimados se comportam de forma semelhante em quantidade e variabilidade aos valores observados. Duarte et al. (2021), ao avaliarem 33 estações em bacias hidrográficas do centro-oeste brasileiro, afirmam que a coerência temporal dos eventos de chuva é reproduzida de forma razoável pelo produto de satélite em questão, uma vez que encontraram valores de coeficiente de correlação entre 0,91 e 0,98 ao compararem os dados mensais de estações meteorológicas com dados do GPM-IMERG. Junior et al. (2021), obtiveram um coeficiente de correlação de 0,93 ao compararem a série histórica de precipitações mensais de 11 estações no Mato Grosso com os dados mensais do GPM para a mesma série.

Para o coeficiente de determinação, os valores variaram entre 0,53 para Poço Verde e 0,80 para Itabaianinha e Brejo Grande. No caso deste parâmetro, com exceção de Poço Verde, que obteve o menor resultado e Santa Rosa de Lima e Piranhas, ambos com 0,69, os demais municípios apresentaram valores satisfatórios a muito bons, quanto a representação do ajuste do modelo. O gráfico resultante da regressão linear realizada para os conjuntos de dados, bem como a equação e reta de tendência do ajuste para cada estação meteorológica, podem ser visualizadas a partir da Figura 4. Nascimento et al. (2021) encontraram um r^2 médio de 0,73 ao compararem os dados mensais de precipitação de 519 estações meteorológicas com os dados mensais do GPM-IMERG para o intervalo entre 2000 e 2018. Vazques-Rodrigues et al. (2024), ao compararem os dados mensais de 30 estações aos dados mensais do GPM-IMERG para

os anos de 2005 a 2018, obtiveram um r^2 de 0,80 para a série de dados.

Quanto ao Erro Médio, é possível notar por meio da Tabela 1, que o GPM apresentou uma tendência de subestimar os valores de precipitação observada para todas as localidades, com exceção de Piranhas. Este comportamento se mostrou mais significativos para os dados de Aracaju e Santa Rosa de Lima, onde os valores de Erro Médio foram respectivamente -39,17 e -32,27 mm/mês. Já municípios com menor volume acumulado mensal de chuva, como Carira e Poço Verde, localizados no clima semiárido, a tendência do GPM-IMERG a subestimar, mostra-se reduzida, uma vez que estas localidades obtiveram Erros Médios respectivamente iguais a -1,05 mm/mês e -10,13 mm/mês. Outros autores como Vazques-Rodriguez et al. (2024) evidenciaram esta tendência de o GPM-IMERG subestimar os dados mensais de precipitação, uma vez que os autores supracitados encontraram valores de EM -27,40 mm/mês para a série de dados estudada.

No entanto, autores como Duarte et al. (2021) e Nascimento et al. (2021) evidenciaram uma tendência de superestima dos dados. Os primeiros encontraram valores entre 1,49 e 23,80 mm/mês, enquanto os segundos encontraram valores entre 41,60 e 56,90 mm/mês.

Para os resultados da REMQ, os valores variaram entre 26,58 mm/mês para Carira e 62,37 mm/mês para Aracaju. O valor encontrado para Aracaju, implica na existência de uma diferença média significativa entre as estimativas do algoritmo e os dados reais de chuva. É importante ressaltar que a REMQ foi calculada comparando as duas séries (dados observados e estimados) inteiramente. No entanto, pode ser que os erros variem nas estações ao longo dos 10 anos de dados. Por exemplo, erros maiores em determinadas estações do ano, provavelmente a chuvosa, podem indicar que o algoritmo de estimativa tem

dificuldades sazonais. Por outro lado, em períodos de estiagem, os erros podem ser menores, tendendo a um menor valor de REMQ. Duarte et al. (2021) encontraram valores de REMQ variando entre 17,96 e 49,35 mm/mês para os dados do GPM-IMERG, o que, de acordo com os autores, é quase o dobro do erro médio, sugerindo que as estatísticas de ordem superior não são reproduzidas adequadamente pelo produto de satélite, o que pode constituir uma limitação importante para a utilização do produto IMERG. Nascimento et al. (2021) ao compararem os dados de 591 estações meteorológicas do Paraná com os dados do GPM-IMERG, obtiveram valores entre 41,60 e 56,90 mm/mês. Vazques-Rodrigues et al. (2024) encontraram 46,64 mm/mês para a REMQ da série de dados do GPM-IMERG entre os anos de 2005 e 2018 em comparação com os dados das 30 estações por eles estudadas.

Quanto ao coeficiente de Willmott, os resultados para todas as estações avaliadas foram elevados, ou seja, muito próximos a 1, variando de 0,83 para Poço Verde e 0,91 para Brejo Grande. Isto indica um elevado índice de concordância

entre os valores observados e estimados. Junior et al. (2021), obtiveram um valor de coeficiente de Willmott equivalente a 0,96 ao compararem os dados do GPM-IMERG com os das 11 estações meteorológicas estudadas. Os autores supracitados encontraram ainda valores coeficiente de Willmott de 0,96 e 0,84 para o TRMM e MERRA respectivamente.

Ao avaliar a Figura 4, é possível observar que de maneira geral, os dados estimados pelo GPM são bastante concisos em relação aos observados pelas estações meteorológicas do INMET e da ANA, e o ajuste é satisfatório, apesar dos valores discrepantes. Ao comparar os valores observados e estimados para municípios os de Poço Verde e Brejo Grande, que obtiveram os melhores ajustes, ambos com r e r^2 iguais a 0,73 e 0,53 e 0,90 e 0,80 respectivamente, notou-se que os valores mínimos observados e estimados e máximos observados e estimados, encontrados para Poço Verde foram de 0,4 mm/mês e 1,06 mm/mês e 176,8 mm/mês e 187,4 mm/mês. Já para Brejo Grande os valores encontrados foram de 1,6 mm/mês e 0,74 mm/mês e 573,8 mm/mês e 354,12 mm/mês.




Figura 4. Gráficos de dispersão dos pontos da variável observada (INMET e ANA) e variável estimada (IMERG) para as estações meteorológicas das localidades estudadas

Estes resultados, juntamente aos resultados de Erro Médio para as estações meteorológicas de Poço Verde e Brejo Grande, fortalecem o indício de que os valores acumulados médios mensais do GPM tendem a ser subestimados, no entanto, esta tendência se pronuncia em relação à medida que o volume de chuva se intensifica e atinge os valores máximos observados.

Para a espacialização dos dados, os resultados se encontram expressos através da Figura 5, onde é possível observar a distribuição espacial gerada pela interpolação das médias anuais, obtidas a partir das médias mensais para as séries de dados de precipitação, além da interpolação dos valores de erro médio.




Figura 5. Distribuição espacial realizada por krigagem ordinária e IDW, para precipitação anual média resultantes do GPM-IMERG e das estações meteorológicas.

Ao avaliar a Figura 5 qualitativamente, é possível observar que, em termos de distribuição espacial dos valores de precipitação média anual, tanto a krigagem como o IDW apresentaram resultados semelhantes. Ou seja, o litoral sergipano concentrou os valores mais elevados de precipitação, enquanto à medida que se percorre em direção ao interior do estado, os valores de precipitação diminuem.

Esta distribuição espacial da precipitação, corrobora para a caracterização do clima sergipano como conhecido, marcado por dois tipos climáticos incidindo majoritariamente sobre o território do estado, com a faixa litorânea apresentando clima tropical e a faixa interiorana com clima semiárido.

Avaliando os resultados apresentados pela Figura 5 quantitativamente, é possível observar que para os dados observados, o IDW obteve valores

mínimos de 461,02 mm/ano e valores máximos de 1303,29 mm/ano de precipitação. Por sua vez a krigagem obteve valores mínimos de 420,27 mm/ano e máximos de 1307,38 mm/ano.

O a distribuição espacial do erro médio para os dos interpoladores foi semelhante, espacialmente e quantitativamente. Para o IDW os valores mínimos variaram entre -24,75 mm/ano e -430,22 e 227,49 mm/ano. Para a krigagem os resultados variaram de -41,81 e 30,85 a -418,40 e 229,89. Estes resultados demarcam, assim como os resultados da Tabela 1, que para valores de precipitação mais elevados, ocorridos na faixa litorânea do estado, o GPM-IMERG possui baixa concordância, como demonstraram a REMQ e o coeficiente de concordância, além da já discutida, tendência de subestimação.

Após avaliados os resultados aqui discutidos, é possível identificar que tais resultados corroboram com o panorama encontrado por autores como Fang et al (2019), Teodoro et al (2020), Peng et al. (2020), Duarte et al (2021), Nascimento et al. (2021), Jiang et al. (2021), Arshad et al. (2021) e Vázquez-Rodríguez (2024), que indicam que os dados do GPM-IMERG possui uma capacidade satisfatória de representar a precipitação, principalmente em escala mensal, mostrando-se superior a outros programas, com uma limitação marcada por resultados menos expressivos em locais de terreno acidentado, clima frio e precipitações anômalas.

Fazendo um paralelo com o trabalho aqui realizado para o estado de Sergipe, nota-se que a região costeira, representada pelas estações meteorológicas de Aracaju e Brejo Grande, com baixas altitudes e clima litorâneo tropical úmido, apesar de terem obtido resultados de r e r^2 mais satisfatórios que as demais estações, obtiveram maiores erros médios e REMQ.

No entanto, não é possível afirmar que a topografia sergipana influencie de forma pronunciada as diferenças climáticas, uma vez que o estado apresenta baixas altitudes na zona costeira, com gradiente de elevação relativamente pequeno em relação ao interior e sem grandes acidentes geográficos como montanhas e serras. No entanto a continentalidade é capaz de influenciar o clima sergipano em áreas mais a Oeste, em contraponto à maritimidade que influencia a costa do estado, a Leste. Esta questão do comportamento do clima e sua relação com a maritimidade e continentalidade é tratada também em Santos, Barros e Ferreira (2023), onde estes afirmam que a continentalidade é um dos fatores fundamentais para explicar as variações climáticas em Sergipe, segundo os autores supracitados, à medida que se afasta do litoral, a precipitação se torna mais escassa, ocorrendo majoritariamente durante o inverno, principalmente durante os meses de maio a julho.

Conclusões

A partir dos resultados obtidos, observou-se que os dados do GPM-IMERG conseguem representar de forma satisfatória as precipitações em escala mensal para o estado de Sergipe, sendo capaz de acompanhar as variações sazonais para os diferentes tipos climáticos que ocorrem no estado, como demonstrado pela interpolação dos valores médios anuais de precipitação. Com base nas análises estatísticas realizadas, foi possível observar que os dados do GPM-IMERG apresentaram correlações moderadas a fortes com os valores observados, com coeficiente de

correlação de Pearson acima de 0,70 para todos os pontos avaliados. O coeficiente de concordância de Willmott também se mostrou elevado, sempre acima de 0,83, indicando uma boa concordância entre os dados estimados e observados.

No entanto, os resultados apontaram uma tendência de subestimação dos dados de precipitação, especialmente em relação aos picos mensais, evidenciada pelos valores negativos de Erro Médio. Esse comportamento foi mais pronunciado em regiões de maior pluviosidade, como o litoral sergipano. A REMQ reforçou essa tendência, com valores mais elevados em áreas costeiras, sugerindo que o algoritmo IMERG pode apresentar dificuldades na estimativa de precipitações mais intensas nessas áreas.

Apesar dessas limitações, a distribuição espacial das precipitações médias anuais, obtida por meio dos métodos de interpolação aplicados, demonstrou que o GPM-IMERG possui grande potencial para ser utilizado em áreas com escassez de dados meteorológicos ou para preenchimento de falhas em séries históricas de estações. Esse potencial foi especialmente notável nas regiões semiáridas, onde a tendência de subestimação foi menos acentuada.

Dessa forma, conclui-se que o produto GPM-IMERG é uma ferramenta promissora para estudos hidrológicos e climáticos em Sergipe, podendo contribuir significativamente para o planejamento e a gestão dos recursos hídricos no estado.

Agradecimentos

Gostaria de agradecer imensamente aos professores e colegas dos Instituto de Ciências Atmosféricas da Universidade Federal de Alagoas e do Programa de Pós-graduação em Geografia da Universidade Federal de Sergipe, pelos ensinamentos e suporte durante minha jornada acadêmica.

Referências

- Agência Nacional de Águas Saneamento Básico. ANA. Monitoramento Hidrológico: Hidroweb v. 3.2.7. <https://www.snirh.gov.br/hidroweb/>. Acessado em: 19 maio 2023.
- Araújo, H. L., Araújo e Silva, T. L., Duarte, S. N., Rodrigues, J. A. M., Araújo, E. L., & dos Santos, A. P. (2022). Análise comparativa entre dados de precipitação observados em superfície e estimados por satélite TRMM na região norte do Tocantins. *Revista Brasileira de Meio Ambiente*, 10(1), 14-22. Disponível em <https://revistabrasileirademeioambiente.com/index.php/RVBMA/article/view/995/317>

- Arshad, M., Ma, X., Yin, J., Ullah, W., Ali, G., Ullah, S., Liu, M., Shahzaman, M., & Ullah, I. (2021). Evaluation of GPM-IMERG and TRMM-3B42 precipitation products over Pakistan. *Atmospheric Research*, 249. <https://doi.org/10.1016/j.atmosres.2020.105341>
- Borges, A., Binda, A. L., Fujita, R. H. (2021). As chuvas do baixo Rio Iguaçu (sudoeste do Paraná) no período de 1976 a 2016. *Geosul*, Florianópolis, 36(78), 64-85. <https://doi.org/10.5007/2177-5230.2021.e71496>
- Brindha, K., Taie Semiromi, M., Boumaiza, L., Mukherjee, S. (2023). Comparing Deterministic and Stochastic Methods in Geospatial Analysis of Groundwater Fluoride Concentration. *Water*, 15(1707). <https://doi.org/10.3390/w15091707>
- Cruz, M. A. S., Mota, P. V. M., Aragão, R., Rocha, R. O. F., (2017). Avaliação das precipitações geradas pelo modelo climático regional ETA-HadGEM2-ES para o Estado de Sergipe. *Scientia Plena*, 13(10). <https://doi.org/10.14808/sci.plena.2017.109913>
- Dembélé, M., Zwart, S. J., (2016). Evaluation and comparison of satellite-based rainfall products in Burkina Faso, West Africa. *International Journal of Remote Sensing* 37, 3995–4014. <https://doi.org/10.1080/01431161.2016.1207258>
- Duarte, L. V., Formiga, K. T. M., Costa, V. A. F. (2022). Analysis of the IMERG-GPM Precipitation Product Analysis in Brazilian Midwestern Basins Considering Different Time and Spatial Scales. *Water*, 14, 2472. <https://doi.org/10.3390/w14162472>
- Fan, Z., Li, W., Jiang, Q., Sun, W., Wen, J. and Gao, J. (2021). A Comparative Study of Four Merging Approaches for Regional Precipitation Estimation, in *IEEE Access*, vol. 9, pp. 33625-33637, <https://doi.org/10.1109/ACCESS.2021.3057057>
- Fang, J., Yang, W., Luan, Y., Dud, J., Lina, A. Zhao, L., (2019). Evaluation of the TRMM 3B42 and GPM IMERG products for extreme precipitation analysis over China. *Atmospheric Research*, 223, 24-38. <https://doi.org/10.1016/j.atmosres.2019.03.001>
- Hou, A.Y., Kakar, R.K., Neeck, S., Azarbarzin, A.A., Kummerow, C.D., Kojima, M., Oki, R., Nakamura, K., Iguchi, T., (2014). The global precipitation measurement mission. *Bulletin of American Meteorological Society* 95, 701–722. <https://doi.org/10.1175/BAMS-D-13-00164.1>
- IBGE. Instituto Brasileiro de Geografia e Estatística. Base de dados georreferenciados do Atlas Digital do Brasil 2010. Portal de mapas do IBGE. <https://portaldemapas.ibge.gov.br/portal.php#homepage>. Acesso em 02 de junho de 2024.
- IBGE. Instituto Brasileiro de Geografia e Estatística. Portal IBGE Cidades. <https://cidades.ibge.gov.br/brasil/se/panorama>. Acessado em 15 de agosto de 2024.
- INMET. Instituto Nacional de Meteorologia. Banco de Dados Meteorológicos. Recuperado de <https://bdmep.inmet.gov.br/>. Acessado em 27 de maio de 2024.
- Jiang, X., Liu, Y., Wu, Y., Wang, G., Zhang, X., Meng, Q., Gu, P., & Liu, T. (2021). Evaluation of the Performance of Multi-Source Precipitation Data in Southwest China. *Water*. <https://doi.org/10.3390/w13223200>
- Junior, A. L. P., Biudes, M. S., Machado, N. G., Vourlitis, G. L., Geli, H. M. E., Santos, L.O.F.d., Querino, C. A. S., Ivo, I.O., Neto, N.L. (2021). Assessment of Remote Sensing and Re-Analysis Estimates of Regional Precipitation over Mato Grosso, Brazil. *Water*, 13(333). <https://doi.org/10.3390/w13030333>
- Kawo, N. S., Hordofa, A. T., Karuppappan, S., (2021). Performance evaluation of GPM-IMERG early and late rainfall estimates over Lake Hawassa catchment, Rift Valley Basin, Ethiopia, *Arabian Journal of Geosciences*, 14(256). <https://doi.org/10.1007/s12517-021-06599-1>
- Khodadoust S. S., Saghafian, B., Moazami, S., (2017). Comprehensive evaluation of 3-hourly TRMM and half-hourly GPM-IMERG satellite precipitation products. *International Journal of Remote Sensing*. 38, 558–571. <https://doi.org/10.1080/01431161.2016.1268735>
- Köppen, W. Das geographische System der Klimate. In: KÖPPEN, W.; GEIGER, R. (Eds): *Handbuch der Klimatologie*. Berlin: Gebrüder Bornträger, Banda 1, Parte C, p. 1-44., 1936.
- Le, M., Lakshmi, V., Bolten, J., & Bui, D. (2020). Adequacy of Satellite-derived Precipitation Estimate for Hydrological Modeling in Vietnam Basins. *Journal of Hydrology*, 586, 124820. <https://doi.org/10.1016/j.jhydrol.2020.124820>
- Levizzani, V., Cattani, E., (2019). Satellite remote sensing of precipitation and the terrestrial water cycle in a changing climate. *Remote Sensing* 11(19). <https://doi.org/10.3390/rs11192301>
- Lima, C. G. da R., Lollo, J. A., Bacani, V.M., Costa, N.R. (2020). Variabilidade espaço-temporal das águas subterrâneas do aquífero Bauru impróprias para o consumo humano: concentrações de Bário, Crômio Total e Vanádio. *Pesquisas em Geociências*, 47(2),

- e096380. <https://doi.org/10.22456/1807-9806.108582>
- Liu, H., Chen, S., Hou, M., & He, L., (2019). Improved inverse distance weighting method application considering spatial autocorrelation in 3D geological modeling. *Earth Science Informatics* 13, 619-632. <https://doi.org/10.1007/s12145-019-00436-6>
- Ly, S., Charles, C., Degré (2011). A. Geostatistical interpolation of daily rainfall at catchment scale: the use of several variogram models in the Ourthe and Ambleve catchments, Belgium. *Hydrol. Earth Syst. Sci.* 15, 2259–2274. <https://doi.org/10.5194/hess-15-2259-2011>
- Maghsood, F. F., Hashemi, H., Hosseini, S. H., & Berndtsson, R. (2019). Ground Validation of GPM IMERG Precipitation Products over Iran. *Remote Sensing* , 12(48). <https://doi.org/10.3390/rs12010048>
- Mahdi, E., Abuzaid, A., & Atta, A. (2020). Empirical variogram for achieving the best valid variogram. *Communications for Statistical Applications and Methods.* 27(5), 547-568 <https://doi.org/10.29220/csam.2020.27.5.547>
- Miri, M., Masoudi, R., & Raziei, T. (2019). Performance Evaluation of Three Satellites-Based Precipitation Data Sets Over Iran. *Journal of the Indian Society of Remote Sensing*, 47(4), 2073 - 2084. <https://doi.org/10.1007/s12524-019-01053-y>.
- Mishra P., Singh U., Pandey C. M., Mishra P., Pandey G. (2019). Application of student's t-test, analysis of variance, and covariance. *Ann Card Anaesth.* 22(4), 407-411. https://doi.org/10.4103/aca.ACA_94_19
- Mondal, A., Lakshmi, V., Hashemi, H. (2018). Intercomparison of trend analysis of Multisatellite Monthly Precipitation Products and Gauge Measurements for River Basins of Indian *Journal of Hydrology*, 565, 779–790. <https://doi.org/10.1016/j.jhydrol.2018.08.083>
- Moraux, A., Dewitte, S., Cornelis, B., Munteanu, A (2021). A deep learning multimodal method for precipitation estimation. *Remote Sensing*, 13(16), 3278. <https://doi.org/10.3390/rs1316327>
- Nascimento, G. J., Althoff, D., Bazame, H. C., Neale, C. M. U., Duarte, S. N., Ruhoff, A. L. Z. (2021). Evaluating the latest IMERG products in a subtropical climate: The case of Paraná State, Brazil. *Remote Sensing*, 13(5), 906. <https://doi.org/10.3390/rs13050906>
- Peng, F., Zhao, S., Chen, C., Cong, D., Wang, Y., & Ouyang, H. (2020). Evaluation and comparison of the precipitation detection ability of multiple satellite products in a typical agriculture area of China. *Atmospheric Research*, 236, 104814. <https://doi.org/10.1016/j.atmosres.2019.104814>
- Pereira, G. W., Valente, D. S. M., Queiroz, D. M. d., Coelho, A. L. d.F., Costa, M. M., Grift, T. (2022). Smart-Map: An Open-Source QGIS Plugin for Digital Mapping Using Machine Learning Techniques and Ordinary Kriging. *Agronomy*, 12(6), 1350. <https://doi.org/10.3390/agronomy12061350>
- Pradhan, R. K., Markonis, Y., Godoy, M. R. V., Villalba-Pradas, A., Andreadis, K. M., Nikolopoulos, E. I., Papalexiou, S. M., Rahim, A. Tapiador, F. J., Hanel, M. (2022). Review of GPM IMERG performance: A global perspective. *Remote Sensing of Environment*, n. 268. <https://doi.org/10.1016/j.rse.2021.112754>
- Sahu, B., Ghosh, A.K. (2021). Seema Deterministic and geostatistical models for predicting soil organic carbon in a 60 ha farm on Inceptisol in Varanasi, India. *Geoderma Reg.*, 26. <https://doi.org/10.1016/j.geodrs.2021.e00413>
- Santos, P. H. N., Barros, G. V. P., Ferreira, W. S., (2023). Perfil climático e cobertura do solo: o cenário do estado de Sergipe. *Revista Brasileira de Geografia Física.* 16(01), 101-115. <https://doi.org/10.26848/rbgf.v16.1.p101-115>
- SRTM. (2000). Shuttle Radar Topography Mission 1 Arc-Second Global (Digital Object Identifier (DOI) number: <https://doi.org/10.5066/F7PR7TFT>
- Tang, G., Clark, M., Papalexiou, S., Ma, Z., & Hong, Y. (2020). Have satellite precipitation products improved over last two decades? A comprehensive comparison of GPM IMERG with nine satellite and reanalysis datasets. *Remote Sensing of Environment*, 240, 111697. <https://doi.org/10.1016/j.rse.2020.111697>
- Teodoro, T. A., dos Passos, R. B., Silva, B. A., da Silva, B. B. (2020). 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*, 43(2), 449-459. Recuperado de https://doi.org/10.11137/2020_2_449_459
- Tercini, O. T., Lima, C. G. da Rocha; Lobo, I. V. Variabilidade espacial e temporal das precipitações na Bacia Hidrográfica do Rio Tietê 1988 a 2017. *Revista Brasileira de Geografia Física*, 17(5), 3974–3991, 2024. <https://doi.org/10.26848/rbgf.v17.5.p3974-3991>
- Tuo, Y., Duan, Z., Disse, M., Chiogna, G., (2016). Evaluation of precipitation input for SWAT modeling in Alpine catchment: A case study in the Adige River basin (Italy). *Science of the*

- total Environment. 573, 66-82.
<https://doi.org/10.1016/j.scitotenv.2016.08.034>
- Vázquez-Rodríguez, D. A., Guerra-Cobián, V. H., Bruster-Flores, J. L., Fonseca, C. R., Yépez-Rincón, F. D. (2024). Evaluating the Performance and Applicability of Satellite Precipitation Products over the Rio Grande–San Juan Basin in Northeast Mexico. *Atmosphere*, 15(749).
<https://doi.org/10.3390/atmos15070749>
- Wang, C., Xu, J., Tang, G., Yang, Y., & Hong, Y. (2020). Infrared Precipitation Estimation Using Convolutional Neural Network. *IEEE Transactions on Geoscience and Remote Sensing*, 1–14.
<https://doi.org/10.1109/tgrs.2020.2989183>
- Willmott, C. J., Ckleson, S. G., Davis, R. E., (1985). Statistics for evaluation and comparisons of models. *Journal of Geophysical Research*, 90(C5), 8995-9005.
<http://dx.doi.org/10.1029/JC090iC05p08995>
- Willmott, C. J., Robeson, S. M., Matsuura, K., (2012). A refined index of model performance, *International Journal of Climatology* 32, 2088-2094. <https://doi.org/10.1002/joc.2419>
- Yu, L., Leng, G., Python, A., Peng, J. (2021). A Comprehensive Evaluation of Latest GPM IMERG V06 Early, Late and Final Precipitation Products across China. *Remote Sensing* 13(6), 1208. <https://doi.org/10.3390/rs13061208>
- Zhang, Y., & Wang, K. (2023). Mapping the representativeness of precipitation measurements in Mainland China. *Environmental Research Letters*, 18. <https://doi.org/10.1088/1748-9326/>