

UNIVERSIDADE FEDERAL DE ALAGOAS
CENTRO DE TECNOLOGIA
ENGENHARIA AMBIENTAL E SANITÁRIA

Pedro Lucas Bernardo Costa

Efeito da mudança climática no padrão dos erros gerados pelas estimativas remotas de precipitação do produto IMERG-GPM

Maceió

2025

Pedro Lucas Bernardo Costa

Efeito da mudança climática no padrão dos erros gerados pelas estimativas remotas de precipitação do produto IMERG-GPM

Plano de Trabalho de Conclusão de Curso apresentado ao curso de Engenharia Ambiental e Sanitária, do Centro de Tecnologia da Universidade Federal de Alagoas, como requisito parcial para obtenção do título de Bacharel em Engenharia Ambiental e Sanitária.

Orientador: Professor Dr. Carlos Ruberto Fragoso Júnior

Maceió

2025

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico

Bibliotecário: Marcelino de Carvalho Freitas Neto – CRB-4 – 1767

C837e Costa, Pedro Lucas Bernardo.

Efeito da mudança climática no padrão dos erros gerados pelas estimativas remotas de precipitação do produto IMERG-GPM / Pedro Lucas Bernardo Costa. – 2024.
55 f.: il.

Orientador: Carlos Ruberto Fragoso Júnior.

Monografia (Trabalho de Conclusão de Curso em Engenharia Ambiental e Sanitária) – Universidade Federal de Alagoas, Centro de Tecnologia, Maceió, 2024.

Bibliografia: f. 50-55.

1. Precipitação (Meteorologia). 2. Sensoriamento remoto. 3. Variáveis meteorológicas. I. Título.

CDU: 551.577

Folha de Aprovação

AUTOR: PEDRO LUCAS BERNARDO COSTA

Efeito da mudança climática no padrão dos erros gerados pelas estimativas remotas
de precipitação do produto IMERG-GPM

Plano de Trabalho de Conclusão de Curso
apresentado ao curso de Engenharia Ambiental e Sanitária, do Centro de Tecnologia da Universidade Federal de Alagoas, como requisito parcial para obtenção do título de Bacharel em Engenharia Ambiental e Sanitária.

Professor Dr. Carlos Ruberto Fragoso Júnior - Universidade Federal de Alagoas
(Orientador)

Banca Examinadora:

Professora Dra. Regina Camara Lins - Universidade Federal de Alagoas

Professor Dr. Manoel Mariano Silva - Universidade Federal de Alagoas

DEDICATÓRIA

Dedico este trabalho a meus pais, Fabiana Bernardo Silva e Álvaro do Nascimento Costa, jamais esquecerei seus esforços, noites de estudo e dedicação constante; e ao meu irmão, João Gabriel Bernardo Costa, nossos monólogos estatísticos sempre serão motivo de boas risadas. Dedico, também, à minha noiva, obrigado por todo apoio e paciência.

AGRADECIMENTOS

Este trabalho é fruto de muitas horas dedicadas à pesquisa científica e a inovação. Agradeço Dr. Carlos Ruberto Fragoso Júnior pelas orientações, conselhos e paciência em direcionar-me para os temas mais relevantes no desenvolvimento do trabalho, este não seria possível sem seu auxílio. Agradeço, também, ao professor Dr. Christopher Freire Souza, principal responsável por fomentar meu interesse pela pesquisa científica, desde o primeiro período do curso, e pelos desafios que ela proporciona, seus conselhos e conversas sobre os mais diversos temas jamais serão esquecidos.

Agradeço à professora Lívia de Maria Calado Machado Soares, pelo incentivo constante, apoio diário e parceria ao longo desta jornada. Sua presença tem contribuído significativamente para meu crescimento pessoal e para o fortalecimento de uma trajetória compartilhada baseada em aprendizado e evolução mútua. Nossos diálogos sobre programação e otimização de código jamais serão esquecidos.

RESUMO

O monitoramento pluviométrico é essencial para estudos hidrológicos, hidráulicos e ambientais, como previsão de cheias, rompimento de barragens e simulações hidrodinâmicas. No entanto, dados de chuva medidos em campo nem sempre estão disponíveis de forma adequada. Os Produtos de Precipitação por Satélite (PPS), como o IMERG-GPM, oferecem estimativas gratuitas e acessíveis, parcialmente suprimindo essa carência. Por se tratar de estimativas, estão sujeitos a erros, os quais podem ser influenciados por variáveis climáticas como temperatura e irradiância solar. Embora haja indícios dessas influências, análises quantitativas sobre o tema ainda são escassas. Desta forma, o objetivo desse trabalho é analisar estatisticamente como a irradiação solar e a temperatura vêm influenciando no padrão de erros das estimativas através de métricas que correlacionam as três variáveis. Utilizou-se o Sertão Alagoano como área de estudo devido ao seu baixo monitoramento pluviométrico. Para isso coletou-se dados de irradiação solar e temperaturas, por meio de um algoritmo que interpola dados medidos em campo ou fornecem os dados em formato de malha (*gridded data*), o BR-DWGD. Posteriormente, foi desenvolvido um algoritmo que utiliza a interpolação bilinear para obtenção de estimativas de precipitação por satélite para qualquer ponto da área de estudo. Também se utilizou o Teste de Correlação de Spearman na determinação de relação entre as variáveis, o Teste de Mann-Kendall na avaliação de tendências e da Análise das Componentes Principais dos dados. O Teste de Spearman retorna que a radiação solar apresentou a maior relação nos dados médios e regionais, com $r_s = 0,213$ e $r_s = 0,532$, respectivamente. O Teste de Mann-Kendall retornou que as temperaturas máximas para a região de interesse apresentam tendência de aumento ao longo dos anos, com um $p - value = 0,02$ e um $z_s = 2,41$. Tais resultados demonstram que há uma correlação entre as variáveis climáticas e o erro pluviométrico e que, pelo menos, uma das variáveis climatológicas vem sofrendo influência das mudanças climáticas. Por fim, a PCA indica correlação entre os erros e a radiação solar, evidenciando o apresentado no teste anterior, além de mapear a distribuição espacial dos dados.

Palavras-chave: precipitação; sensoriamento remoto; variáveis meteorológicas.

ABSTRACT

Rainfall monitoring is essential for hydrological, hydraulic, and environmental studies, such as flood forecasting, dam failure, and hydrodynamic simulations. However, field-measured rainfall data are not always adequately available. Satellite Precipitation Products (PPS), such as IMERG-GPM, offer free and accessible estimates, partially filling this gap. Since these are estimates, they are subject to errors, which can be influenced by climate variables such as temperature and solar irradiance. Although there is evidence of these influences, quantitative analyses on the subject are still scarce. Thus, the objective of this study is to statistically analyze how solar irradiance and temperature have been influencing the error pattern of estimates through metrics that correlate the three variables. The Sertão Alagoano region was used as the study area due to its low rainfall monitoring. For this purpose, solar irradiation and temperature data were collected using an algorithm that interpolates data measured in the field or provides data in a gridded data format, the BR-DWGD. Subsequently, an algorithm was developed that uses bilinear interpolation to obtain satellite precipitation estimates for any point in the study area. The Spearman Correlation Test was also used to determine the relationship between the variables, the Mann-Kendall Test to assess trends, and the Principal Component Analysis of the data. The Spearman Test returns that solar radiation presented the greatest relationship in the average and regional data, with $r_s = 0.213$, and $r_s = 0.532$, respectively. The Mann-Kendall Test returned that the maximum temperatures for the region of interest show an increasing trend over the years, with a $p - value = 0.02$, and a $z_s = 2.41$. These results demonstrate a correlation between the climate variables and the rainfall error, and that at least one of the climatological variables has been influenced by climate change. Finally, the PCA indicates a correlation between the errors and solar radiation, evidencing what was presented in the previous test, in addition to mapping the spatial distribution of the data.

Keywords: rainfall; remote sensing; meteorological variables.

LISTA DE FIGURAS

Figura 1 - Os objetivos específicos que devem compor este trabalho.	15
Figura 2 - Esquema representativo dos quatro elementos fundamentais do sensoriamento remoto (adaptado de NOVO, 2001)	17
Figura 3 - Espectro eletromagnético e suas principais regiões (Fonte: NOVO, 2001)	18
Figura 4 - Conceito da propagação de ondas eletromagnéticas. A onda é formada por duas componentes, a elétrica (E) e a magnética (M) (Fonte: LILLESAND; KIEFER; CHIPMAN, 2015).....	18
Figura 5 - Sensoriamento Remoto dos recursos terrestres (Fonte: LILLESAND; KIEFER; CHIPMAN, 2015).....	19
Figura 6 – Satélite principal da missão GPM (Fonte: NASA).	20
Figura 7 - Canais coletados pelo sensor com diferentes frequências das micro-ondas (Fonte: NASA).....	21
Figura 8 - Visualização da chuva realizada pelo DPR em três dimensões (Fonte: NASA).	22
Figura 9 – Croqui do sensor GMI do GPM (Fonte: DRAPER & NEWELL, 2010).....	23
Figura 10 - Algumas temperaturas vistas no universo. (Fonte: adaptado de HALLIDAY <i>et al.</i> , 2009)	25
Figura 11 - Metodologia aplicada no desenvolvimento do trabalho.....	30
Figura 12 - Mapa do estado de Alagoas com delimitação das regiões ambientais e com destaque para o Sertão.	31
Figura 13 - Mapa do estado de Alagoas destacando suas estações pluviométricas.	32
Figura 14 - Estrutura do algoritmo para obtenção e análise dos dados de chuva.....	33
Figura 15 - Malha de controle utilizada pelo satélite para obter as estimativas de chuva.....	35
Figura 16 – Croqui do Sertão Alagoano demonstrando a composição da estação virtual.....	36
Figura 17 - Exemplo do método aplicado na interpolação bilinear.	37
Figura 18 - Séries históricas diárias da precipitação observada, radiação solar, temperatura máxima e mínima para a estação Delmiro Gouveia (937013).	41

Figura 19 - Série temporal dos dados observados e estimados para os dados diários, mensais acumulados e anuais acumulados para a estação Delmiro Gouveia (937013).....	42
Figura 20 - Diagrama de dispersão dos dados diários, médias mensais e médias anuais para as variáveis climatológicas da estação Delmiro Gouveia (937013).....	43
Figura 21 - Análise dos Componentes Principais dos Postos Pluviométricos e das variáveis climáticas estudadas.	46

LISTA DE TABELAS

Tabela 1 - Estações utilizadas, seus códigos e porcentagem de falhas.	40
Tabela 2 - Intervalo de disponibilidade temporal das variáveis climatológicas utilizadas no estudo.....	40
Tabela 3 - Valor-p das variáveis climatológicas analisadas.	44
Tabela 4 - Resultados do teste de correlação de Spearman para o Eoe e as outras variáveis climáticas.	44
Tabela 5 - Valor-p referente ao teste de Mann-Kendall das variáveis analisadas.....	45

SUMÁRIO

1	INTRODUÇÃO.....	12
2	OBJETIVOS.....	15
2.1	Objetivo Geral	15
2.2	Objetivos Específicos	15
3	FUNDAMENTAÇÃO TEÓRICA	17
3.1	Sensoriamento Remoto.....	17
3.2	Irradiância Solar	23
3.3	Temperatura.....	24
3.4	Análise Estatística.....	26
4	MATERIAIS E MÉTODOS	30
4.1	Área de estudo.....	30
4.2	Série Temporal de Precipitação	32
4.3	Série Temporal de Temperatura e Irradiação Solar	37
4.4	Analisar erros e correlações.....	38
5	RESULTADOS	40
6	CONCLUSÕES.....	48
	REFERÊNCIAS.....	49

1 INTRODUÇÃO

A precipitação é o principal componente do ciclo hidrológico devido ao seu papel significativo em várias atividades socioeconômicas (AMORIM *et al.*, 2020). Seu monitoramento adequado é crucial para diversas aplicações climáticas e hidrológicas (PRAKASH *et al.*, 2018), porém tal monitoramento é desafiador em algumas regiões, visto que uma rede pluviométrica com alta densidade requer equipamentos com custos elevados (TERINK *et al.*, 2018). Em países como o Brasil, com uma grande área de ocupação, a rede de monitoramento é desigual, acarretando grandes áreas com baixa caracterização hidrológica (MONTEIRO *et al.*, 2015).

Informações confiáveis sobre a precipitação desempenham um papel fundamental na gestão dos recursos hídricos (MIRÓ *et al.*, 2017). Um dos primeiros estágios dos estudos hidrológicos e meteorológicos é a obtenção de dados contínuos e confiáveis sobre a chuva (SATTARI *et al.*, 2017). Os dados pluviométricos das estações *in situ* representam a principal fonte de dados observados (TAPIADOR *et al.*, 2012), os quais são utilizados para calibração e validação de outras fontes de dados e na modelagem hidrológica (AMORIM *et al.*, 2020).

Obter uma rede de monitoramento pluviométrico contínuo, sem falhas e com uma densidade temporal extensa ainda é um desafio, segundo Gadelha *et al.* (2019). Pois, para tal é preciso que a estação seja devidamente acompanhada, pois do contrário vários problemas na medição podem ocorrer. Há várias razões para isso, por exemplo: erros nos mecanismos de gravação, danos nos instrumentos de medida, erros nas medições e perdas dos registros manuscritos (CALDERA *et al.*, 2016), sendo essas as possíveis causas de erros sistemáticos. Este problema é particularmente mais significativo em países em desenvolvimento, como o Brasil, onde há poucas estações e muitas lacunas nas séries de dados dos postos pluviométricos existentes (RADI *et al.*, 2015). Além disso, a baixa densidade de observações e a não existência de postos sobre os oceanos torna a interpolação da precipitação para grades regulares, geralmente, um produto de baixa qualidade (ROZANTE *et al.*, 2010).

Para superar essas limitações, Produtos de Precipitação por Satélite (PPS) são uma alternativa potencialmente viável, visto que possuem um monitoramento ininterrupto (até a desativação do satélite) e espacialmente distribuídos em escala quase global. Os PPS são um dos produtos do sensoriamento remoto para monitoramento da precipitação. Vários produtos de precipitação por satélite foram mesclados para

criar o Sistema Integrado de Estimativa de Precipitação Multi-Satélite para Medição da Precipitação Global (IMERG-GPM, do inglês), conforme Huffman *et al.* (2014).

O IMERG tem grande potencial de uso, especialmente em áreas da superfície terrestre onde os instrumentos de medição (estações pluviométricas) não estão presentes ou que possuem muitas falhas, por exemplo nos oceanos e em áreas remotas. O IMERG combina as estimativas de precipitação coletadas durante a operação do satélite *Tropical Rainfall Measuring Mission* (TRMM), cujo foi lançado em órbita em Novembro de 1997 (KUMMEROW *et al.*, 2000) e finalizou em 2015, com as estimativas de precipitação coletadas pela missão GPM (2014 – até o momento), criando uma série temporal contínua de precipitação com aproximadamente 25 anos de dados. Este produto possui uma altíssima resolução espacial de 0,1° de latitude por 0,1° de longitude (cerca de 11 km no estado de Alagoas, Brasil) e uma resolução temporal de até meia hora.

Os PPS possuem escala global, mas cada região possui características climáticas únicas que podem afetar as estimativas de chuva. Por exemplo, Tan *et al.* (2016) identifica erros nas estimativas do IMERG, apenas, em áreas costeiras, alertando ao leitor que a metodologia utilizada em outras áreas possa ser diferente. O Brasil possui diferentes tipos de climas: equatorial, semiárido, tropical, tropical atlântico, tropical de altitude e subtropical. Os diferentes tipos climáticos que ocorrem num determinado território são condicionados pelo que chamamos de fatores climáticos: maritimidade, massas de ar e latitude são os que afetam grandemente o território brasileiro. Diante dessa heterogeneidade, modelos climáticos sofrem grande variabilidade e uma forma de obter estimativas mais precisas são os dados colhidos pelos PPS.

Em locais como o Sertão Alagoano, nordeste brasileiro, segundo Cordeiro & Blanco (2020), as estimativas pluviométricas via satélite tendem a apresentar melhor representatividade (menores erros em relação aos dados observados) quando usadas em regiões com baixa pluviometria, porém quando há uma baixa densidade de monitoramento *in situ* essa validação tende a ficar prejudicada, possuindo menores correlações com os postos pluviométricos (ZHAO & MA, 2019).

Porém as estimativas fornecidas por satélite também apresentam erros, devido a vários procedimentos de combinação entre satélites e correção de viés (DUAN *et al.*, 2015), ou a fenômenos climáticos que atingem certas regiões do globo, como o *El Niño* e *La Niña*, a Zona de Convergência Intertropical e a Zona de Convergência do Atlântico Sul (CORDEIRO *et al.*, 2020), luminosidade e erros nas nuvens (erros que

alteram a acurácia e/ou precisão das estimativas por conta da conexão indireta entre as estimativas de precipitação e a temperatura no topo das nuvens), segundo Tan *et al.* (2016).

Diante desses erros, é comum fazer análise dos dados de satélite para determinada região, verificar o padrão dos erros (entre dado observado e estimado) e aplicar correções de viés para que se aproximem das estações observadas mais próximas (quando existem). Porém, certos fenômenos climáticos vêm se alterando com o tempo devido às mudanças climáticas, que alteram/aumentam variáveis como a temperatura (AVILA-DIAZ *et al.*, 2020) e a irradiância solar. Poucos estudos foram elaborados no Brasil, até então, tentando verificar a influência dessas variáveis nos erros das estimativas de satélite. Logo, avaliar a influência desses fatores é de grande importância para que as estimativas de chuva via satélite gerem mais confiança para os usuários.

2 OBJETIVOS

A seguir são apresentados o objetivo geral e os objetivos específicos para a composição deste trabalho.

2.1 Objetivo Geral

Objetivo Geral foi avaliar a influência da alteração de padrões climáticos na estimativa de chuvas obtidas pelo produto IMERG-GPM. 2 variáveis estão sendo analisadas de modo a compreender suas anomalias no tempo e como tais eventos influenciam nas chuvas obtidas por satélite.

2.2 Objetivos Específicos

Os objetivos específicos que irão compor este trabalho são baseados mormente em 4 fases, conforme Figura 1 e descrição logo abaixo:

Objetivos Específicos




Figura 1 - Os objetivos específicos que devem compor este trabalho.

Os objetivos apresentados na figura supracitada são descritos da seguinte forma:

- a) Identificar nas séries históricas de temperatura e da irradiância solar (variáveis climáticas), que influenciam a precipitação, alterações nos padrões de comportamento;
- b) Quantificar os erros envolvidos nas estimativas de chuvas a partir do produto IMERG-GPM;
- c) Avaliar a relação entre o comportamento dos erros e o comportamento das variáveis climáticas escolhidas.

A fase **a** gira em torno dos procedimentos de obtenção e organização dos dados, para tal usou-se um algoritmo facilitador. A fase **b** é baseada na obtenção das estimativas de chuvas do satélite e na comparação com os dados observados. Utilizou-se outro algoritmo para obter os dados do satélite, cujo é mais detalhado na metodologia. A fase **c** é a de avaliação dos dados, nessa fase com os dados coletados e manipulados realiza-se um estudo estatístico para verificar a existência de alguma relação entre os dados.

3 FUNDAMENTAÇÃO TEÓRICA

A seguir são apresentadas as fundamentações que corroboram para o desenvolvimento do trabalho.

3.1 Sensoriamento Remoto

A definição clássica do termo sensoriamento remoto refere-se a um conjunto de técnicas/instrumentos destinados à obtenção de informações sobre objetos, sem que haja contato físico entre eles (NOVO, 2001). Essa obtenção de informações passa a Radiação Eletromagnética e é composta por uma fonte emissora de radiação, um objeto alvo, que irá receber a radiação e um sensor que irá captar uma parcela dessa radiação, conforme Figura 2:




Figura 2 - Esquema representativo dos quatro elementos fundamentais do sensoriamento remoto
(adaptado de NOVO, 2001)

A fonte emissora é qualquer objeto que possua a capacidade de emitir radiação eletromagnética, sendo essa radiação pertencente ao espectro eletromagnético, conforme Figura 3:

o espectro eletromagnético




Figura 3 - Espectro eletromagnético e suas principais regiões (Fonte: NOVO, 2001)

A radiação eletromagnética é uma forma de energia, que se propaga como uma onda, de acordo com a teoria básica da onda. Como mostrado na Figura 4, esta teoria descreve que a energia eletromagnética se propaga de maneira harmônica e senoidal na velocidade da luz (c).




Figura 4 - Conceito da propagação de ondas eletromagnéticas. A onda é formada por duas componentes, a elétrica (E) e a magnética (M) (Fonte: LILLESAND; KIEFER; CHIPMAN, 2015).

A distância do pico de uma onda até a onda mais próxima é o comprimento de onda (λ) e o número de picos passando em um ponto fixo no espaço por unidade de tempo é a frequência da onda (ν) (LILLESAND; KIEFER; CHIPMAN, 2015).

A partir da física básica, as ondas seguem a lei geral expressa na equação(1:

$$c = v\lambda \quad (1)$$

O sensor coleta a radiação refletida pelo alvo, que não é igual à que foi emitida pela fonte, representando uma parcela do todo. O alvo é qualquer objeto que reflita a radiação eletromagnética emitida pela fonte e representa o elemento cuja informação é desejada. Por fim, o sensor é o instrumento capaz de coletar a radiação eletromagnética refletida pelo alvo.

Alguns autores apresentam o sensoriamento remoto com base em 2 processos, a aquisição do dado e a análise do dado. A Figura 5 ilustra tal ideia:




Figura 5 - Sensoriamento Remoto dos recursos terrestres (Fonte: LILLESAND; KIEFER; CHIPMAN, 2015).

A aquisição do dado é realizada por sensores presentes em aviões e/ou satélites, resultando na geração de dados sensoriais em formato digital ou pictográfico (*pictorial*). A análise dos dados consiste no uso de vários dispositivos que visualizam e interpretam o dado *pictorial*, ou o uso de computadores para analisar os dados digitais. Dados *Pictorial* são informações dispostas em imagens, facilitando o entendimento e o uso, por exemplo, um MDE (Modelo Digital de Elevação) é uma imagem, cujo cada pixel representa um valor de elevação. As informações são compiladas, em mapas, tabelas, ou dados geoespaciais e apresentada ao usuário, que aplicará seu processo de decisão (LILLESAND; KIEFER; CHIPMAN, 2015).

Apresentado os conceitos gerais, vale a pena entender como a chuva é estimada por sensores acoplados no satélite, sendo, neste caso, o GPM, conforme Figura 6:




Figura 6 – Satélite principal da missão GPM (Fonte: NASA).

O satélite principal da missão GPM é capaz de coletar estimativas de chuva por meio de dois sensores radiométricos presentes na estrutura do satélite, sendo eles:

- GPM Microwave Imager (GMI);
- Dual-frequency Precipitation Radar (DPR).

O GMI é um sensor passivo, ou seja, ele não emite ondas eletromagnéticas, apenas recebe. Este instrumento coleta as micro-ondas emitidas pela atmosfera terrestre. As micro-ondas ocupam uma faixa de frequências, conforme o espectro eletromagnético, as diferentes frequências presentes nessa faixa geram diferentes resultados para o sensor. A depender da frequência da onda recebida, o GMI pode interpretar como sendo chuva ou neve, por exemplo. Para que haja uma grande caracterização dos diferentes tipos de pluviometrias, o sensor opera em diferentes canais de frequência (*multi-channel*), 13 ao todo, variando de 10 GHz a 183 GHz, conforme a Figura 7.




Figura 7 - Canais coletados pelo sensor com diferentes frequências das micro-ondas (Fonte: NASA).

Em seguida, essas diferentes frequências de onda são convertidas em valores de precipitação. Na verdade, o sensor mede a temperatura de brilho, que é a energia radiante da atmosfera e isso é convertido, por meio de equações, em chuva ou neve. Porém, há limitações nas taxas de precipitação coletadas, o GMI suporta o monitoramento de uma faixa entre 0,2 e 60,0 mm/h (SKOFRONICK-JACKSON *et al.*, 2017). Em relação a disponibilidade do dado, tal sensor disponibiliza os dados de precipitação após 1 hora da coleta. Tais características tornam o GMI um dos melhores tipos de sensores radiométricos de micro-ondas passivos (WENTZ & DRAPER, 2016).

O DPR é um sensor ativo, ou seja, ele emite as micro-ondas e recebe a onda refletida pela atmosfera. Ele possui dois radares, cujos são capazes de coletar informações da precipitação em duas bandas (faixas de frequência), na banda Ka (opera a 35,5 GHz) e na banda Ku (opera a 13,6 GHz). Seu diferencial está na capacidade de observar a chuva em 3 dimensões, conforme demonstrado na Figura 8:




Figura 8 - Visualização da chuva realizada pelo DPR em três dimensões (Fonte: NASA).

Mesmo com um sistema de coleta de dados robusto, o satélite pode apresentar erros. Certas variáveis podem afetar o desempenho das estimativas, alguns estudos já avaliaram o desempenho de satélites que fornecem estimativas de chuva, frente a diferentes condições topográficas, como no platô tibetano (WANG *et al.*, 2020) e nas terras altas da Finlândia (MAHMOUD *et al.*, 2021), ou como as estimativas do satélite não seguem o padrão pluviométrico observado em regiões com grandes elevações topográficas (> 2000 m de altitude) (SHARMA *et al.*, 2020).

Sui *et al.* (2020) além de trazer questões topográficas, também mostra que há uma maior quantidade de incertezas nas estimativas em regiões urbanas e em corpos d'água, indicando que o uso e cobertura do solo é uma variável relevante para o desempenho do satélite.

O primeiro passo para a modelagem de erros é reconhecer fatores físicos responsáveis e então avaliar as magnitudes dos erros relacionados (BHUIYAN *et al.*, 2020). Bhuiyan *et al.* (2020) apresentou as temperaturas máximas e mínimas como um fator responsável por gerar erros nas estimativas do satélite.

Outra variável climática que pode gerar erros nas estimativas de satélite é a radiação solar, pois ela acaba aquecendo um instrumento chave na calibração do dispositivo, o *hot load*. Tal instrumento deveria manter-se a uma temperatura constante

para servir de referência, porém os métodos utilizados para proteger o aquecimento do *hot load* ou as equações de calibração ainda geram imprecisões, principalmente relacionados à antena do satélite (DRAPER & NEWELL, 2010). A Figura 9 apresenta um exemplo do instrumento usado no satélite para a aquisição dos dados:




Figura 9 – Croqui do sensor GMI do GPM (Fonte: DRAPER & NEWELL, 2010).

3.2 Irradiância Solar

A radiação solar é o fluxo de energia transmitido pelo Sol sob a forma de radiação eletromagnética (GÓMEZ, 2018). A radiação solar pode ser medida de duas formas: a Irradiância Solar Total (TSI – *Total Solar Irradiance*) e a Irradiância Solar Espectral (SSI – *Solar Spectral Irradiance*). A Irradiância Solar Total é a potência total de energia proveniente do Sol por unidade de área por comprimento de onda a 1 UA (Unidade Astronômica – distância entre o sol e a Terra) medida em $\text{W.m}^{-2}.\text{nm}^{-1}$ e ao longo de todo o espectro eletromagnético. A Irradiância Solar Espectral é medida para diferentes comprimentos de onda, como ultravioleta ou infravermelho. Atrelado a esses conceitos está a irradiação solar, que é a potência total de energia proveniente do Sol recebida por um corpo por unidade de tempo, medida em W.h.m^{-2} .

A irradiância solar está interligada ao clima terrestre e afeta diversos componentes da atmosfera. Por exemplo, a relação entre a irradiância espectral ultravioleta e o clima estratosférico vem sendo estudada, mas há poucos dados observados e muito do que é previsto é baseado em modelos (ERMOLLI, 2013). Okoro (2021) tenta

traçar uma correspondência entre as variações da irradiância solar e as variações de chuva na região, mostrando que a irradiância atinge seu pico nas épocas mais secas do ano. O estudo de Lu (2021) mostra que as anomalias da irradiância solar na região da troposfera pode inibir a precipitação, cujo afeta o desempenho do IMERG-GPM. Cabe avaliar quantitativamente o déficit no desempenho do produto de satélite para a área de estudo deste trabalho.

3.3 Temperatura

A temperatura é uma grandeza física que mede o grau de agitação das moléculas que compõem um corpo. Seu entendimento é importante para diversas áreas, por exemplo, os meteorologistas analisam a transferência de energia térmica nos eventos associados ao fenômeno El Niño e ao aquecimento global (HALLIDAY *et al.*, 2009). Os engenheiros ambientais utilizam os valores de temperatura em estudos hidrológicos, estatísticos e na modelagem hidrodinâmica. A temperatura é medida em kelvin (K) no Sistema Internacional, mas no Brasil usualmente utiliza-se a escala Celsius, cuja unidade é o grau Celsius (°C). Na natureza a temperatura varia constantemente, por exemplo, a superfície do Sol possui uma temperatura próxima a 10.000 K (aproximadamente 9.727 °C), mas seu centro pode chegar a 10^7 (10 milhões) K. A Figura 10 apresenta algumas temperaturas que foram/são presentes no universo na escala Kelvin (HALLIDAY *et al.*, 2009).




Figura 10 - Algumas temperaturas vistas no universo. (Fonte: adaptado de HALLIDAY *et al.*, 2009)

A medição adequada da temperatura é muito útil no desenvolvimento de estudos relacionados ao monitoramento da precipitação por satélite. Pois, a temperatura é um fator crucial tanto na precipitação quanto em sua obtenção via satélite. O IMERG-GPM pode obter estimativas da precipitação de duas maneiras, através das micro-ondas com um instrumento acoplado no satélite chamado GPM Microwave Imager (GMI) e por meio de um instrumento de radar, o Dual-frequency Precipitation Radar (DPR). A energia das micro-ondas relaciona-se com a chuva por meio da emissão, absorção e dispersão, pois para baixas frequências (10 a 37 GHz), é registrada a emissão térmica das gotículas de chuva e em altas frequências (maior que 85 GHz) é registrada a dispersão da radiação que sai da superfície terrestre, devido a partículas de gelo na camada de chuva, e topos de sistemas convectivos (JOYCE *et al.*, 2004).

As temperaturas vêm aumentando com o passar do tempo por conta de questões relacionadas às mudanças climáticas, consequentemente os padrões de precipitação (AVILA-DIAZ *et al.*, 2020). O uso operacional de dados de satélite possui erros e sua relação com diferentes temperaturas ainda é uma lacuna científica, mas já há a

noção de que a temperatura provoca mudanças nas estimativas. Logo, entender essa relação é crucial para o adequado uso de tais dados (HOSSEINI-MOGHARI & TANG, 2022). Portanto, parte desse TCC consiste em verificar as mudanças de temperatura ao longo do tempo e como elas influenciam nos padrões dos erros gerados pelas estimativas de satélite.

3.4 Análise Estatística

Neste trabalho os dados precisaram passar por um conjunto de processos baseados em métodos estatísticos para garantir, ou não, a existência de correlações e tendências. Tal processo é denominado de análise estatística. A primeira metodologia abordada foi o teste de Shapiro-Wilk.

O teste de Shapiro-Wilk (SHAPIRO & WILK, 1965) verifica se um conjunto de dados segue uma distribuição normal. Ele calcula um valor estatístico (W) baseado na correlação entre os valores ordenados da amostra e os valores esperados para uma distribuição normal. O valor- p resultante do teste é interpretado da seguinte forma:

- Se $p > 0.05$, não há evidências estatísticas para rejeitar a hipótese nula, indicando que os dados podem ser considerados normalmente distribuídos.
- Se $p \leq 0.05$, a hipótese nula é rejeitada, sugerindo que os dados não seguem uma distribuição normal.

O valor- p (p -value) é um conceito da estatística utilizado para testar hipóteses e avaliar a significância de um resultado. Ele representa a probabilidade de obter um resultado tão ou mais extremo do que o observado nos dados, assumindo que a hipótese nula (H_0) seja verdadeira (WASSERMAN, 2003). Pode-se aplicar o valor- p em qualquer teste de hipótese usado nesse trabalho, mudando apenas o tipo do teste para o qual o valor- p será calculado. Os tipos são bilateral, unilateral à esquerda e unilateral à direita, porém as ferramentas computacionais já classificam o tipo do teste usado e calculam o respectivo valor- p .

A aplicação do teste de Shapiro-Wilk é realizada para determinar quais métodos serão utilizados na correlação e análises de tendências das variáveis. Se os dados seguem uma distribuição normal, métodos paramétricos, como a comparação de médias, são adequados. Caso contrário, testes não paramétricos devem ser empregados garantindo a validade conceitual da análise.

Uma metodologia muito utilizada na caracterização da correlação entre duas variáveis é o diagrama de dispersão. Ele é um gráfico de pares de dados quantitativos (x, y), com um eixo x horizontal, para a primeira variável, e um eixo y vertical, para a segunda variável, o padrão dos pontos marcados é, em geral, útil para se determinar a existência, ou não, de uma correlação (relação) entre as duas variáveis (TRIOLA, 2017). Embora um diagrama de dispersão seja subjetivo, é sempre aconselhável construir-se um primeiro, de modo a vermos características que não podem ser observadas em uma lista de dados emparelhados (TRIOLA, 2017). Neste trabalho o diagrama serviu de base na avaliação da correlação entre as variáveis estudadas.

Uma métrica utilizada para avaliar correlação entre duas variáveis, de maneira objetiva, é o teste de correlação de postos de Spearman. Ele é um teste não paramétrico que usa postos de dados amostrais que consistem em pares combinados para associar duas variáveis (TRIOLA, 2017). Segundo Triola (2017), há duas vantagens nessa metodologia:

1. Diferentemente dos métodos paramétricos, o método de correlação de postos não exige uma distribuição normal para nenhuma população;
2. A correlação de postos pode ser usada para detectar algumas (não todas) relações que não são lineares.

A estatística (r_s) é obtida com base na Equação (2), apresentada a seguir:

$$r_s = 1 - \frac{6 \sum d^2}{n(n^2 - 1)} \quad (2)$$

Sendo:

- r_s : Estatística de teste da correlação de postos de Spearman;
- d : Diferença entre as posições para os dois valores de um par;
- n : Número de pares de amostras.

Utilizou-se, também, o teste de Mann-Kendall para analisar a existência de alguma tendência nas variáveis climatológicas, de modo que corrobore com a hipótese da influência das mudanças climáticas nos dados. O teste de tendência de Mann-Kendall (MANN, 1945; KENDALL, 1975) é um teste não paramétrico bem utilizado para detectar tendências em séries temporais (GAVRILOV *et al.*, 2016; PRABHAKAR *et al.*, 2018; SHIVAM *et al.*, 2019). A estatística do teste normal padrão é calculada com base na Equação (3):

$$z_s = \begin{cases} \frac{S - 1}{\sqrt{Var(S)}}, & \text{se } S > 0 \\ 0, & \text{se } S = 0 \\ \frac{S + 1}{\sqrt{Var(S)}}, & \text{se } S < 0 \end{cases} \quad (3)$$

Sendo:

- S : A estatística do teste;
- $Var(S)$: A variância da estatística do teste;

A estatística do teste é calculada com base na Equação (4):

$$S = \sum_{i=n}^{n-1} \sum_{j=i+1}^n sng(x_j - x_i) \quad (4)$$

Sendo:

- n : O número de pontos de dados;
- x_i e x_j : Os respectivos valores dos dados nos tempos i e j ($j > i$);
- sng : Função sinal.

A função sinal é calculada com base na Equação (5), apresentada a seguir:

$$sng(x_j - x_i) = \begin{cases} +1, & \text{se } x_j - x_i > 0 \\ 0, & \text{se } x_j - x_i = 0 \\ -1, & \text{se } x_j - x_i < 0 \end{cases} \quad (5)$$

Valores positivos de z_s indicam tendências crescentes, enquanto valores negativos indicam tendências decrescentes e valor nulo indica que não foi identificada tendência na amostra de dados.

Por fim, a Análise dos Componentes Principais (PCA) foi aplicada. A PCA é uma análise estatística que simplifica a complexidade de grandes quantidades de dados, reduzindo a dimensionalidade de modo a manter os padrões e tendências que eles expressam (Lever, *et al.*, 2017). Conforme Jolliffe (2002), a ideia central da PCA é reduzir a dimensionalidade de muitas variáveis interrelacionadas, mantendo a variação do conjunto de dados. Os conjuntos de variáveis são transformados em Componentes Principais, que não são correlacionadas, e que são ordenadas para que a primeira Componente retenha a maior parte da variação presente e isso vá reduzindo com o aumento das componentes.

A PCA utiliza a decomposição espectral da matriz de covariância dos dados, expressa pela Equação (6), apresentada a seguir:

$$C = \frac{1}{m-1} X^T X \quad (6)$$

Sendo:

- X: Matriz m x n;
- m: Número de amostras da matriz;
- n: Número de variáveis;
- C: Matriz de Covariância.

A decomposição espectral calcula os autovetores e autovalores da matriz C, os autovalores representam a magnitude da variação e os autovetores apresentam as direções. Tais conceitos serão visualizados na seção de resultados e sua aplicação na seção com as metodologias.

4 MATERIAIS E MÉTODOS

A metodologia utilizada neste estudo é, majoritariamente, dividida em duas partes: (i) o desenvolvimento do algoritmo de coleta das estimativas de chuva; e (ii) a análise estatística dos dados de irradiância solar, temperatura, chuva e erros, com o objetivo de verificar a mudança no padrão de erros ao longo do tempo, conforme apresentado na Figura 11.




Figura 11 - Metodologia aplicada no desenvolvimento do trabalho.

4.1 Área de estudo

A área escolhida é o Sertão alagoano, localizado na porção oeste do Estado de Alagoas, conforme a Figura 12. Tal região engloba duas Regiões Ambientais (RA): o Sertão e o Sertão do São Francisco.




Figura 12 - Mapa do estado de Alagoas com delimitação das regiões ambientais e com destaque para o Sertão.

A área escolhida é o Sertão alagoano (composto pelo Sertão e pelo Sertão do São Francisco), que conta com 35 municípios. A região vem ganhando visibilidade desde a evolução do canal do Sertão (SILVA, 2019). Esse canal possibilitou a expansão dos perímetros de irrigação, os quais, aliados à chuva, contribuíram para a melhoria da produtividade agrícola na área. Contudo, devido à ocorrência de veranicos – períodos secos em estações chuvosas (iniciando em abril e finalizando em outubro) – o setor agrícola tem sido prejudicado (CARVALHO *et al.*, 2013). Além disso, esse local está inserido no polígono das secas e apresenta um regime pluviométrico caracterizado por extrema irregularidade espaço-temporal. Nesse cenário, a escassez hídrica constitui um entrave para o desenvolvimento econômico e para a subsistência da população (GONZAGA, 2011).

Aliados a esses fatores, a baixa intensidade e a irregularidade pluviométrica no Sertão propiciam modificações no ciclo hidrológico. Em ambientes com climas áridos e semiáridos, como é o caso, gera-se erosão superficial, perda de fertilidade e redução da biodiversidade (GONZAGA, 2011). Diante dessas características, o Sertão Alagoano é um ótimo candidato a receber contribuições de mapeamento de precipitação

por satélite, pois, com o monitoramento adequado é possível prever épocas de seca ou, ao menos, gerar probabilidades de ocorrência mais condizentes com a realidade.

Na Figura 13, é possível ver que a densidade da rede de monitoramento é maior em regiões mais próximas ao litoral e menor no oeste do Estado (Sertão Alagoano).




Figura 13 - Mapa do estado de Alagoas destacando suas estações pluviométricas.

De acordo com o Sistema de Informações de Recursos Hídricos de Alagoas (SIRH, 2022), o Estado possui, ao todo, 563 estações pluviométricas, cujas fontes de dados são a Agência Nacional de Águas e Saneamento Básico (ANA), o Centro Nacional de Monitoramento e Alertas de Desastres (Cemaden), o Instituto Nacional de Meteorologia (INMET) e fontes locais.

O Sertão alagoano possui 95 estações de monitoramento pluviométrico, sendo que, apenas, 12 possuem dados no período analisado, de acordo com dados coletados do SIRH (2022), representando, aproximadamente, 13% do todo.

4.2 Série Temporal de Precipitação

Na obtenção da série temporal de precipitação estimada criou-se o algoritmo RainSat. Sua estrutura é apresentada na Figura 14 e seu código é de acesso aberto

(open-source), estando disponível em: https://github.com/flow-ufal/gpm_precipitation_tools/tree/sertao.




Figura 14 - Estrutura do algoritmo para obtenção e análise dos dados de chuva.

Inicialmente, optou-se por obter séries históricas de precipitação observada pelo SIRH da SEMARH/AL (<https://sirh.al.gov.br/>). Os dados observados foram utilizados para validar os valores de precipitação obtidos por satélite, comparando o valor medido por estações pluviométricas em terra com o valor monitorado pelo IMERG-GPM para uma célula (pixel delimitado por 4 pares de longitude e latitude). Vale destacar que tal processo é necessário, pois os dados hidrológicos utilizados em diversos estudos têm como referência os dados observados por postos pluviométricos (SALIO *et al.*, 2015).

Tal comparação deveria ser garantida por dois critérios: o temporal e o da distância. Os dados do satélite analisado começaram a ser divulgados no ano 2000 e estão disponíveis até hoje. Portanto, o posto pluviométrico precisa apresentar dados nesse mesmo intervalo e não ter mais de 10% de falhas ao longo da série histórica de interesse para não prejudicar a análise (PEREIRA *et al.*, 2024; ARAÚJO *et al.*, 2023).

Além disso, as estações não podem estar muito próximas umas das outras, pois o produto obtém dados de precipitação com uma resolução espacial de $0,1^\circ \times 0,1^\circ$. Assim, estações muito próximas geram resultados idênticos em relação ao produto IMERG-GPM, afetando a comparação com uma estação.

Para garantir uma distância adequada entre as estações selecionadas, utilizou-se o *software* Quantum GIS (QGIS), ferramenta empregada para análises geoespaciais. No QGIS, foi gerada uma grade retangular com a função “*Create grid...*”, na qual os vértices estão espaçados a cada $0,1^\circ$ de longitude e $0,1^\circ$ de latitude, conforme o Sistema de Referência de Coordenadas (SRC) geográficas SIRGAS 2000 (EPSG: 4674).

Após a seleção das estações é possível levantar dados referentes a acumulados anuais e mensais e a distribuição dos quantis pluviométricos das estações, visando a obtenção de dados relevantes sobre o regime pluviométrico da região em estudo.

A principal função do algoritmo é a obtenção dos dados de satélite para preencher lacunas nos dados observados e obter mais estimativas para a zona de interesse. Cada dado do satélite armazena valores de precipitação para todo o Brasil para um único intervalo de tempo, então, para cada intervalo há um arquivo. Cada chuva está espaçada $0,1^\circ \times 0,1^\circ$ no país, portanto, em média por arquivo há 924.924 valores de precipitação.

O algoritmo possui a classe Gpm, cuja obtém estimativas de chuva por satélite a partir de uma entrada par de longitude e latitude, compondo a sua respectiva “estação virtual”, sendo esta inexistente *in loco*, mas estimada por satélite. O satélite obtém um valor de chuva para cada célula em uma malha, conforme Figura 15.




Figura 15 - Malha de controle utilizada pelo satélite para obter as estimativas de chuva.

O valor da célula fica situado no centro geométrico dela, porém se o usuário fornece um par longitude/latitude que não seja o centro geométrico, uma interpolação é feita com base nas 4 células mais próximas para compor o resultado da estação virtual, conforme Figura 16.




Figura 16 – Croqui do Sertão Alagoano demonstrando a composição da estação virtual.

A estação virtual é consequência de uma interpolação bilinear realizada entre os 4 pontos em azul na figura supracitada, conforme Figura 17, cuja leva em consideração x (longitude), y (latitude) e Q_{ij} (precipitação no centro geométrico de cada célula), sendo P o valor da precipitação na estação virtual.




Figura 17 - Exemplo do método aplicado na interpolação bilinear.

A interpolação bilinear combina duas interpolações lineares para calcular o valor de um ponto em um espaço bidimensional. Com base na figura supracitada, a fórmula para calcular P é apresentada na Equação (7):

$$P(x, y) = \frac{(x_2 - x)(y_2 - y)}{(x_2 - x_1)(y_2 - y_1)} Q_{11} + \frac{(x - x_1)(y_2 - y)}{(x_2 - x_1)(y_2 - y_1)} Q_{21} + \frac{(x_2 - x)(y - y_1)}{(x_2 - x_1)(y_2 - y_1)} Q_{12} + \frac{(x - x_1)(y - y_1)}{(x_2 - x_1)(y_2 - y_1)} Q_{22} \quad (7)$$

Assim, as chuvas são obtidas para qualquer ponto da região de interesse, facilitando a comparação.

4.3 Série Temporal de Temperatura e Irradiação Solar

Na obtenção das séries temporais de temperatura e irradiação solar utilizou-se o algoritmo *Brazilian Daily Weather Gridded Data* (BR-DWGD) (XAVIER *et al.*, 2022) em pontos da região de estudo que são ocupados por estações pluviométricas.

O algoritmo funciona por meio de 2 etapas: a etapa de extração e processamentos dos dados e a etapa de interpolação espacial. Os dados observados de temperatura máxima/mínima e radiação solar são coletados das redes de estações meteorológicas da ANA e do INMET. Foram aplicados controles de qualidade para eliminar valores fora de intervalos pré-estabelecidos. Destaca-se que, neste item, o termo radiação solar faz referência a irradiância solar, como explicado no item 3.2.

Para a Radiação solar (R_s), os valores são filtrados com base na Radiação extraterrestre (R_a), de modo que: $0,03 R_a \leq R_s < R_a$. Para as temperaturas máximas (T_{max}) e mínimas (T_{min}): $-30^\circ\text{C} < T_{max}$ e $T_{min} < 50^\circ\text{C}$. Além disso, as temperaturas também passaram por um ajuste para compensar a influência da altitude.

Com base em uma amostra de 1.375 estações climatológicas, verificou-se que a taxa de decaimento da temperatura em relação a altitude (*temperature lapse rate*) é de $0,006^\circ\text{C}/\text{m}$. Ou seja, se uma estação a 1.500 m de altitude registra uma temperatura de 20°C , um ponto de grade a 1.000 m de altitude deve registrar uma temperatura de 23°C .

Após a preparação dos dados, o algoritmo utiliza métodos de interpolação para gerar valores em cada célula da grade com resolução de $0,1^\circ \times 0,1^\circ$. Utilizou-se um método de interpolação baseado no *Inverse Distance Weighting* (IDW) e o *Angular Distance Weighting* (ADW). Essas abordagens integradas permitem a geração de um produto *gridded* consistente, que auxiliou na composição dos dados deste trabalho

4.4 Analisar erros e correlações

Com os dados obtidos, analisou estatisticamente através de métricas, como o Coeficiente de Correlação de Spearman, valor de P (*p-value*) e o Teste de Mann-Kendall, as correlações entre as variáveis climáticas, a rejeição das hipóteses e as tendências climáticas, respectivamente. O objetivo é encontrar alguma correlação entre os dados analisados, sendo o erro entre chuva observada e chuva estimada (E_{oe}) a variável sempre presente nos emparelhamentos.

O valor de P é uma métrica que informa a probabilidade da hipótese nula (H_0) ser verdadeira. No presente trabalho a H_0 é que não há influência da radiação solar e das temperaturas no E_{oe} . Já a Hipótese Alternativa (H_1), é que essa influência, ou correlação, existe.

As equações utilizadas na determinação de correlação por meio do Teste de Spearman são apresentadas no item 3.4, além dessas, calculou-se o valor crítico do teste, com base na Equação (8):

$$r_s = \frac{\pm z}{\sqrt{n - 1}} \quad (8)$$

Sendo:

- z : Nível de significância (se $\alpha = 0,05$, $z = 1,96$).

Caso o resultado da estatística de teste esteja dentro do intervalo calculado para os valores críticos, deixa-se de rejeitar a hipótese nula, o que indica nenhuma correlação.

Já o Teste de Mann-Kendall foi calculado pelo algoritmo de código aberto *py-MannKendall* (HUSSAIN & MAHMUD, 2019), utilizando o teste original apresentado no item 3.4. O teste buscou avaliar tendências de aumento ou diminuição para as variáveis climáticas utilizadas.

Por fim, a análise PCA fez uso das funções do pacote *scikit-learn* em Python (BUITINCK *et al.*, 2013), tendo como parâmetro de entrada as variáveis analisadas e um número de componentes igual a 2. Tal valor corresponde ao número de componentes que são capazes de capturar a maior parte da variância.

5 RESULTADOS

O primeiro passo foi coletar os dados de chuva observada para estações pluviométrica do sertão alagoano. Com base no item 4.1 e **Erro! Fonte de referência não encontrada.**, das 12 estações, apenas, 5 possuem menos que 10% de falhas no período analisado. A Tabela 1 apresenta tais estações:

Tabela 1 - Estações utilizadas, seus códigos e porcentagem de falhas.

Nome	Código	Falhas (%)
Delmiro Gouveia	937013	0,01
Piranhas	937023	0,87
Pão de Açúcar	937018	1,24
Santana do Ipanema	937032	0,90
Traipu	936076	0,03

Em seguida, utilizou-se o algoritmo BR-DWGD, conforme item **Erro! Fonte de referência não encontrada.**, para coletar os dados interpolados da irradiação solar (RS), da temperatura máxima (TMÁX) e mínima (TMÍN) para o local em que a estação pluviométrica está localizada, como exemplo, a estação Delmiro Gouveia com longitude: -37,9942 e latitude: -9,3928. Destaca-se que, a radiação solar é apresentada em função da energia (Joules), e não em função da potência (Watts).

Os dados foram obtidos para o período de 02/06/2000 a 31/07/2020, para interseccionar os períodos de dados disponíveis da precipitação estimada, da radiação e das temperaturas. A Tabela 2 indica o intervalo de disponibilidade dos dados coletados:

Tabela 2 - Intervalo de disponibilidade temporal das variáveis climatológicas utilizadas no estudo.

Variável Climatológica	Data Inicial da Amostra	Data Final da Amostra
Precipitação Estimada	02/06/2000	29/03/2025
Radiação Solar	01/01/1961	31/07/2020
Temperaturas	01/01/1961	31/07/2020

A Figura 18 apresenta as séries históricas das variáveis em estudo para a estação Delmiro Gouveia:




Figura 18 - Séries históricas diárias da precipitação observada, radiação solar, temperatura máxima e mínima para a estação Delmiro Gouveia (937013).

Após mapear todos os dados observados, comparou-se as precipitações observadas e as estimadas, com relação aos dados diários, mensais acumulados e anuais acumulados. A Figura 19 apresenta tal comparação para estação Delmiro Gouveia:




Figura 19 - Série temporal dos dados observados e estimados para os dados diários, mensais acumulados e anuais acumulados para a estação Delmiro Gouveia (937013).

Observa-se que os dados estimados aparentam superestimar os dados observados. Seguindo com o objetivo do trabalho, o erro entre as precipitações foi calculado com base na Equação (9):

$$Eoe_i = o_i - e_i \quad (9)$$

Sendo:

- Eoe_i : Erro entre a chuva observada e estimada para o i -ésimo dado (mm);
- o_i : Chuva observada para o i -ésimo dado (mm);
- e_i : Chuva estimada para o i -ésimo dado (mm).

Em seguida elaborou-se um diagrama de dispersão para verificar uma possível correlação entre os dados, a primeira coluna apresenta os dados diários, a segunda a média mensal e a terceira a média anual. A primeira linha relaciona o Eoe e radiação solar, a segunda relaciona Eoe e temperatura máxima e a terceira o Eoe e temperatura mínima. A Figura 20 apresenta o diagrama para a estação Delmiro Gouveia:




Figura 20 - Diagrama de dispersão dos dados diários, médias mensais e médias anuais para as variáveis climatológicas da estação Delmiro Gouveia (937013).

Através da análise subjetiva do gráfico, percebe-se que não há correlação entre os dados. De modo a fazer uma avaliação mais objetiva e com base em métricas estatísticas utilizou-se o teste de Shapiro-Wilk para determinar a normalidade das séries climáticas. A Tabela 3 apresenta o valor-p das variáveis para todas as estações e para o Sertão Alagoano:

Tabela 3 - Valor-p das variáveis climatológicas analisadas.

Variável	Eoe	RS	TMÁX	TMÍN
Estação	Valor-p			
937013	9,13e-14	9,77e-10	2,76e-9	3,74e-4
937023	1,00	3,26e-9	6,13e-10	1,44e-6
937018	1,00	1,73e-8	3,07e-9	7,99e-6
937032	1,00	7,78e-9	4,48e-10	6,32e-6
936076	5,14e-9	1,21e-7	7,43e-10	4,09e-6
Média	0,60	3,08e-8	1,53e-9	7,88e-5
Sertão	2,47e-8	4,06e-9	8,25e-10	5,83e-6

Com base nos valores p médios calculados, o teste sugere que há evidências para afirmar que, pelo menos, o *Eoe* apresenta uma distribuição paramétrica dos dados, com base na análise pontual, entretanto tal afirmação não se sustenta para toda a região de estudo. Logo, utilizou-se uma métrica de avaliação da correlação entre dados não paramétricos e paramétricos, o teste de correlação de Spearman. Os resultados da estatística de teste de Spearman são apresentados na Tabela 4 para todas as estações:

Tabela 4 - Resultados do teste de correlação de Spearman para o *Eoe* e as outras variáveis climáticas.

Estação	937013	937023	937018	937032	936076	Média	Sertão
Variável	Estatística de Spearman para o <i>Eoe</i>						
Eoe	1,000	1,000	1,000	1,000	1,000	1,000	1,000
RS	0,565	0,165	0,115	-0,175	0,397	0,213	0,532
TMÁX	0,572	0,145	0,184	-0,203	0,336	0,207	0,446
TMÍN	0,332	0,091	0,109	-0,132	0,193	0,119	0,221

Como o valor crítico do teste é de $\pm 0,126$, conforme os resultados médios pontuais, com exceção da Temperatura mínima, a temperatura máxima e a radiação solar apresentam uma correlação moderada (COHEN, 1992), colaborando com Bhuiyan *et al.* (2020), que indicou a temperatura mínima como a menor influenciadora sobre os erros das precipitações e máxima como a maior, tendo como referências as variáveis deste trabalho, visto o estudo citado não avaliou radiação solar. Já do ponto de vista dos resultados regionais (Sertão Alagoano), todas as variáveis climatológicas apresentam algum nível de correlação, sendo a temperatura mínima de nível moderado e a radiação solar e a temperatura máxima de nível forte (COHEN, 1992).

Por fim, avaliou-se a tendência de aumento ou diminuição das variáveis climáticas, por meio do valor-p do teste de Mann-Kendall, os resultados do teste são apresentados na Tabela 5 para todas as estações:

Tabela 5 - Valor-p referente ao teste de Mann-Kendall das variáveis analisadas.

Estação	Métrica	Eoe	RS	TMÁX	TMÍN
937013	Valor-p	0,323	0,726	0,010 ⁽¹⁾	0,205
937023		0,001	0,094	0,260	0,130
937018		0,233	0,030 ⁽²⁾	0,756	0,484
937032		0,000 ⁽³⁾	0,600	0,260	0,668
936076		0,761	0,419	0,016 ⁽⁴⁾	0,122
Média		0,264	0,374	0,260	0,322
Sertão		0,181	0,323	0,02 ⁽⁵⁾	0,332

(1) A temperatura máxima para a estação Delmiro Gouveia apresenta tendência de crescimento;

(2) A radiação solar para a estação Pão de Açúcar apresenta tendência de crescimento;

(3) Valor muito baixo para 3 casas decimais, porém não é nulo;

(4) A temperatura máxima para a estação Traipu apresenta tendência de crescimento;

(5) A temperatura máxima para a região do Sertão Alagoano apresenta tendência de crescimento com $z_S = 2,41$.

Os resultados médios sugerem que a H_0 (não há tendência) são válidas para todas as variáveis climáticas analisadas. Tais resultados podem estar vinculados ao uso de dados, em sua maioria, interpolados, conforme apresentado no item **Erro! Fonte de referência não encontrada.** e **Erro! Fonte de referência não encontrada.**, que são baseados em cálculos estimados. Em relação à análise regional (Sertão Alagoano), a temperatura máxima apresenta tendência de aumento no tempo (Avila-Diaz, 2020; Costa *et al.*, 2020), o que apresenta conformidade com estudos recentes.

Por fim, elaborou-se a PCA das variáveis abordadas neste trabalho, a Figura 21 apresenta tal análise:




Figura 21 - Análise dos Componentes Principais dos Postos Pluviométricos e das variáveis climáticas estudadas.

A partir da PCA é possível verificar algumas informações. Analisando a distribuição dos pontos de dados dos postos pluviométricos nota-se que Santana do Ipanema e Delmiro Gouveia estão localizados na porção esquerda do gráfico, enquanto Pão de Açúcar, Piranhas e Traipu estão na porção direita. Estes postos estão, todos, localizados na margem do Rio São Francisco, ao contrário daqueles, evidenciando, possivelmente, a capacidade da PCA na divisão espacial dos dados com base nos padrões hidrológicos.

Outra análise de suma importância é a direção dos vetores que representam as variabilidades das variáveis climáticas. Nota-se que os Erros e a Radiação Solar apresentam uma correlação identificada pela proximidade e direção dos vetores, algo que é comprovado pelo teste de Spearman. Entretanto, a PCA não identifica uma relação clara entre os Erros e a Temperatura Máxima, além de apresentar uma relação inversamente proporcional entre Temperatura Mínima e os Erros, visto que os ângulos entre os vetores são próximos, respectivamente de 90° e 180° .

Conforme exposto no item 4.4, foram utilizadas 2 componentes, pois essas conseguem reter a maior parte da variabilidade dos dados, com 56% retido pela Componente 1 e 28% retido pela componente 2. A porcentagem restante, cerca de 16%, está

distribuída nas outras sucessivas componentes. Porém, visto que 84% da variabilidade está retida em duas componentes, a variabilidade, correlação e distribuição dos dados consegue ser capturada adequadamente.

Desta maneira, foi possível avaliar as possíveis correlações entre as variáveis apresentadas neste trabalho e como elas afetam as estimativas de precipitação por satélite.

6 CONCLUSÕES

Logo, analisando o diagrama de dispersão e o Teste de Correlação de Spearman, conclui-se que há uma correlação entre os dados de radiação solar, temperatura máxima e os erros, tanto para a análise pontual como a regional. Tal resultado é fundamental para confirmar a influência das variáveis climáticas nos erros das precipitações.

Já o Teste de Mann-Kendall mostra uma tendência de crescimento da temperatura máxima ao longo dos anos com base em uma análise regional da área de estudo, o que traz à tona o exposto por alguns estudos recentes que revelam a influência das mudanças climáticas nas temperaturas do sertão nordestino e que como consequência têm impacto nos erros das precipitações. Em relação às outras variáveis climáticas, um dos fatores que podem impactar na ausência de tendência e correlações seria o período analisado de 20 anos, que é inferior ao período de uma Normal Climatológica, 30 anos.

Por fim, a PCA conseguiu capturar a distribuição espacial dos dados, além de confirmar a correlação dos Erros com a radiação solar. Tal análise, pode ser mais eficaz com o uso de mais estações, o que será possível com o aumento da área de estudo.

Espera-se que esse trabalho possa ser um ponto de partida no entendimento das precipitações estimadas por satélite no Sertão Alagoano, visto que não há outros estudos na área que avaliem tais erros juntamente com tais variáveis climáticas.

REFERÊNCIAS

- AMORIM, J. D. S.; VIOLA, M.R.; JUNQUEIRA, R.; OLIVEIRA, V.A.D.; MELLO, C. R. D. Evaluation of Satellite Precipitation Products for Hydrological Modeling in the Brazilian Cerrado Biome. **Water**, v. 12, p. 2571, set. 2020.
- ARAÚJO, A. R.; DUTRA, R. M. S.; PEREIRA, U. C.; NUNES, F. G.; FERREIRA, M. E. Análise de Métodos de Preenchimento de Falhas em Dados Pluviométricos para a Região de Planejamento Sudoeste de Mato Grosso, Brasil. **Revista Brasileira de Geografia Física**, v. 16, p. 2271-2286, jul. 2023.
- AVILA-DIAZ, A.; BENEZOLI, V.; JUSTINO, F.; TORRES, R.; WILSON, A. Assessing current and future trends of climate extremes across Brazil based on reanalyses and Earth system model projections. **Climate Dynamics**, v. 55, p. 1403-1426, jun. 2020.
- BHUIYAN, M. A. E.; YANG, F.; BISWAS, N. K.; RAHAT, S. H.; NEELAM, T. J. Machine Learning-Based Error Modeling to Improve GPM IMERG Precipitation Product over the Brahmaputra River Basin. **Forecasting**, v. 2, p. 248-266, jul. 2020. DOI: <https://doi.org/10.3390/forecast2030014>.
- BUITINCK, L.; LOUPPE, G.; BLONDEL, M.; PEDREGOSA, F.; MUELLER, A.; GRISSEL, O.; NICULAE, V.; PRETTENHOFER, P.; GRAMFORT, A.; GROBLER, J.; LAYTON, R.; VANDERPLAS, J.; JOLY, A.; HOLT, B.; VAROQUAUX, G. API design for machine learning software: experiences from the scikit-learn project. **European Conference on Machine Learning and Principles and Practices of Knowledge Discovery in Databases**, v. 1, set. 2013. DOI: <https://doi.org/10.48550/arXiv.1309.0238>.
- CALDERA, H.P.G.M.; PIYATHISSE, V.R.P.C.; NANDALAL, K.D.W. A Comparison of Methods os Estimating Missing Daily Rainfall Data. **The Institution of Engineers**, v. 49, n. 4, p. 1-8, nov. 2016. DOI: <http://dx.doi.org/10.4038/engineer.v49i4.7232>.
- CARVALHO, A. L.; SOUZA, J. L.; LYRA, G. B.; SILVA, E. C. Estação chuvosa e de cultivo para a região de Rio Largo, Alagoas, baseada em métodos diretos e sua relação com o El Niño – Oscilação Sul. **Revista Brasileira de Meteorologia**, v. 28, n. 2, p. 192-198, jun. 2013. DOI: <https://doi.org/10.1590/S0102-77862013000200008>.
- COHEN, J. Statistical power analysis. **Current Directions in Psychological Science**, v. 1, p. 98–101, jun. 1992. DOI: <https://doi.org/10.1111/1467-8721.ep10768783>.
- CORDEIRO, A. L. M.; BLANCO, C. J. C. Assessment of satellite Products for filling rainfall data gaps in the Amazon region. **Natural Resource Modeling**, v. 34, n. 2, nov. 2020.

- COSTA, R. L.; BAPTISTA, G. M. M.; GOMES, H. B.; SILVA, F. D. S.; JÚNIOR, R. L. R.; SALVADOR, M. A.; HERDIES, D. L. Analysis of climate extremes índices over northeast Brazil from 1961 to 2014. **Weather and Climate Extremes**, v. 28, jun. 2020.
- DRAPER, D.; NEWELL, D. Global Precipitation Measurement (GPM) Microwave Imager (GMI). **2010 11th Specialist Meeting on Microwave Radiometry and Remote Sensing of the Environment**, p. 236-240, ago. 2010. DOI: <https://doi.org/10.1109/MICRORAD.2010.5559555>.
- DUAN, Y.; WILSON, A. M.; BARROS, A. P. Scoping a field experiment: Error diagnostics of TRMM precipitation radar estimates in complex terrain as a basis for IPHEX2014. **Hydrology & Earth System Sciences**, v. 19, p. 1501–1520, mar. 2015. DOI: <https://doi.org/10.5194/hess-19-1501-2015>.
- ERMOLLI, I.; MATTHES, K.; DUDOK DE WIT, T.; KRIVOVA, N. A.; TOURPALI, K.; WEBER, M.; UNRUH, Y. C.; GRAY, L.; LANGEMATZ, U.; PILEWSKIE, P.; ROZANOV, E.; SCHMUTZ, W.; SHAPIRO, A.; SOLANKI, S. K.; WOODS, T. N. Recent variability of the solar spectral irradiance and its impact on climate modelling. **Atmospheric Chemistry and Physics**, v. 13, p. 3945–3977, mar. 2013.
- GADELHA, A. N.; COELHO, V. H. R.; XAVIER, A. C.; BARBOSA, L. R.; MELO, D. C. D.; XUAN, Y.; HUFFMAN, G. J.; PETERSEN, W. A.; ALMEIDA, C. N. Grid box-level evaluation of IMERG over Brazil at various space and time scales. **Atmospheric Research**, v. 218, p. 231–244, abr. 2019. DOI: <https://doi.org/10.1016/j.atmos-res.2018.12.001>.
- GAVRILOV, M.B.; TOŠIĆ, I.; MARKOVIĆ, S.B.; UNKAŠEVIĆ, M.; PETROVIĆ, P. Analysis of annual and seasonal temperature trends using the Mann-Kendall test in Vojvodina, Serbia. **Idojaras**, v. 120, p. 183-198, jun. 2016.
- GÓMEZ, J. M. R.; CARLESSA, F.; VIEIRA, L. E.; SILVA, L. A irradiância solar: conceitos básicos. **Revista Brasileira de Ensino de Física**, v. 40, n. 3, fev. 2018. DOI: <http://dx.doi.org/10.1590/1806-9126-RBEF-2017-0342>.
- GONZAGA, E.; SANTOS, V.; NICÁCIO, R. Análise do comportamento do NDVI e NDWI em períodos de diferentes intensidades pluviométricas no Sertão alagoano. **XV Simpósio Brasileiro de Sensoriamento Remoto**, p. 1736, 2011.
- HALLIDAY, D.; RESNICK, R.; WALKER, J. Fundamentos de Física. 8. ed. Rio de Janeiro: LTC, 2009.

- HOSSEINI-MOGHARI, S.; TANG, Q. Can IMERG data capture the scaling of precipitation extremes with temperature at different time scales?. **Geophysical Research Letters**, v. 49, n.3, jan. 2022.
- HUFFMAN, G. J.; BOLVIN, D. T.; BRAITHWAITE, D.; HSU, K.; JOYCE, R.; KIDD, C.; NELKIN, E. J.; SOROOSHIAN, S.; TAN, J.; XIE, P. IMERG ATBD: NASA Global Precipitation Measurement (GPM) Integrated Multi-satellitE Retrievals for GPM (IMERG). 6. ed. Estados Unidos da América: **NASA**, 2020.
- HUSSAIN, M. M.; MAHMUD, I. pyMannKendall: a python package for non parametric Mann Kendall Family of trend tests. **The Journal of Open Source Software**, v. 4, p. 1556, 2019.
- JOLLIFFE, I. T. Principal Component Analysis. 2. ed. New York: Springer, 2002.
- JOYCE, R. J.; JANOWIAK, J. E.; ARKIN, P. A.; XIE, P. CMORPH: A method that produces global precipitation estimates from passive microwave and infrared data at high spatial and temporal resolution. **Journal of hydrometeorology**, v. 5, n. 3, p. 487–503, jun. 2004.
- KENDALL, M.G. Rank Correlation Methods. 4. ed. Londres: Charles Griffin, 1975.
- 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.; SMITH, E. A.; WILHEI, 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 and Climatology**, v. 39, p. 1965-1982, dec. 2000.
- LEVER, J.; KRZYWINSKI, M.; ALTMAN, N. Principal Component Analysis. **Nature Methods**, v. 14, p. 641-642, jun. 2017.
- LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. Remote Sensing and Image Interpretation. 7. ed. Estados Unidos da América: **Wiley**, 2015.
- LU, C.; YE, J.; FANG, G.; HUANG, X.; YAN, M. Assessment of GPM IMERG Satellite Precipitation Estimation under Complex Climatic and Topographic Conditions. **Atmosphere**, v. 12, jun. 2021. DOI: <https://doi.org/10.3390/atmos12060780>.
- MAHMOUD, M. T.; MOHAMMED, S.A.; HAMOUDA, M.A.; DAL MASO, M.; MOHAMMED, M. M. Performance of the IMERG Precipitation Products over High-latitudes Region of Finland. **Remote Sensing**, v. 13, p. 2073, mai. 2021. DOI: <https://doi.org/10.3390/rs13112073>.

- MANN, H. B.; Nonparametric Tests Against Trend. **Econometrica**, v. 13, p. 245-259, jul. 1945.
- MIRÓ, J. J.; CASELLES, V.; ESTRELA, M. J. Multiple imputation of rainfall missing data in the Iberian Mediterranean context. **Atmospheric Research**, v. 197, p. 313–330, nov. 2017.
- MONTEIRO, J. A. F.; STRAUCH, M.; SRINIVASAN, R.; ABBASPOUR, K.; GÜCKER, B. Accuracy of grid precipitation data for Brazil: application in river discharge modelling of the Tocantins catchment. *Hydrological Processes*, v. 30, p. 1419-1430, out. 2015. DOI: <https://doi.org/10.1002/hyp.10708>.
- NOVO, E. M. L. M.; PONZONI, F. J.; Introdução ao sensoriamento remoto. São Jose dos Campos: 2001.
- OKORO, E. C.; UGWU, E. B. I.; ONAH, I. G.; OMEJE, L. C. Rainfall and solar irradiance monitoring in Nsukka zone, Nigeria. **European Journal of Statistics and Probability**, v. 9, p. 1-10, 2021.
- PRABHAKAR, A.K.; SINGH, K. K.; LOHANI, A.K. Regional level long-term rainfall variability assessment using Mann-Kendall test over the Odisha state of India. **Journal Agrometeorology**, v. 20, p. 164-165, 2018.
- PRAKASH, S.; MITRA, A. K.; AGHAKOUCHAK, A.; LIU, Z.; NOROUZI, H.; PAI, D.S. A preliminar assessment of GPM-based multi-satellite precipitation estimates over a monsoon dominated region. **Journal of Hydrology**, v. 556, p. 865-876, jan. 2018. DOI: <https://doi.org/10.1016/j.jhydrol.2016.01.029>.
- PEREIRA, A. R. B.; COSTA, C. T. F.; FIRMINO, P. R. A.; STUDART, T. M. C.; OLIVEIRA, C. W. Preenchimento de falhas em séries de dados meteorológicos de estações automáticas. **Revista Brasileira de Climatologia**, v. 35, p. 22-44, jul. 2024. DOI: <https://doi.org/10.55761/abclima.v35i20.17599>.
- PEREIRA, E. B.; MARTINS, F. R.; GONÇALVES, A. R.; COSTA, R. S.; LIMA, F. L.; RÜTHER, R.; ABREU, S. L.; TIEPOLO, G. M.; PEREIRA, S. V.; SOUZA, J. G. Atlas brasileiro de energia solar. 2. ed. São José dos Campos: **INPE**, 2017.
- RADI, N. F. A.; ZAKARIA, R.; AZMAN, M. A. Z. Estimation of missing rainfall data using spatial interpolation and imputation methods. **AIP Conference Proceedings**, v. 1643, p. 42-48, fev. 2015. DOI: <http://dx.doi.org/10.1063/1.4907423>.
- ROZANTE, J. R.; MOREIRA, D. S.; GONCALVES, L. G. G.; VILA, D. A. Combining TRMM and Surface Observations of Precipitation: Technique and Validation over

South America. **Weather and Forecasting**, v. 25, p. 885-894, jun. 2010. DOI: <https://doi.org/10.1175/2010WAF2222325.1>.

SALIO, P.; HOBOUCHIAN, M. P.; GARCÍA SKABAR, Y.; VILA, D. Evaluation of high-resolution satellite precipitation estimates over Southern South America using dense rain gauge network. **Atmospheric Research**, v. 163, p. 146-161, set. 2015. DOI: <https://doi.org/10.1016/j.atmosres.2014.11.017>.

SATTARI, M.; REZAZADEH-JOUDI, A.; KUSIAK, A. Assessment of different methods for estimation of missing data in precipitation studies. **Hydrology Research**, v. 48, n. 4, p. 1032–1044, ago. 2017. DOI: <https://doi.org/10.2166/nh.2016.364>.

SHARMA, S.; CHEN, Y.; ZHOU, X.; YANG, K.; LI, X.; NIU, X.; HU, X.; KHADKA, N. Evaluation of GPM-Era Satellite Precipitation Products on the Southern Slopes of the Central Himalayas Against Rain Gauge Data. **Remote Sensing**, v. 12, p. 1836, jun. 2020. DOI: <https://doi.org/10.3390/rs12111836>.

SHAPIRO, S. S.; WILK, M. B. An Analysis of Variance Test for Normality (complete samples). **Biometrika**, v. 52, p. 591-611, dez. 1965.

SHIVAM, G.; GOYAL, M. K.; SARMA, A. K. Index-Based Study of Future Precipitation Changes over Subansiri River Catchment under Changing Climate. **Journal of Environmental Informatics**, v. 34, jan. 2018.

SILVA, S.; SILVA, C.; SOUZA, J.; SOUSA, A.; ARAÚJO, E. Uso Econômico da Água para o Feijão Caupi na Região do Sertão Alagoano. **REBAGRO**, v. 9, p. 07-13, 2019.

SKOFRONICK-JACKSON, G.; PETERSEN, W. A.; BERG, W.; KIDD, C.; STOCKER, E. F.; KIRSCHBAUM, D. B.; KAKAR, R.; BRAUN, S. A.; HUFFMAN, G. J.; IGUCHI, T.; KIRSTETTER, P. E.; KUMMEROW, C.; MENEGHINI, R.; OKI, R.; OLSON, W. S.; TAKAYABU, Y. N.; FURUKAWA, K.; WILHEIT, T. The Global Precipitation Measurement (GPM) Mission for Science and Society. **Bulletin of the American Meteorological Society**, v. 98, p. 1679-1695, ago. 2017. DOI: <https://doi.org/10.1175/BAMS-D-15-00306.1>.

TAN, J.; PETERSEN, W.A.; TOKAY, A. A novel approach to identify sources of errors in IMERG for GPM ground validation. **J. Hydrometeorol**, v. 17, p. 2477–2491, 2016.

TENRIK, W.; LEIJNSE, H.; EERTWEGH, G.; UIJLENHOET, R. Spatial resolution in areal rainfall estimation and their impact on Hydrological simulations of a lowland catchment. **Journal of Hydrology**, v. 563, p. 319-335, ago. 2018. DOI: <https://doi.org/10.1016/j.jhydrol.2018.05.045>.

- TAPIADOR, F. J.; TURK, F. J.; PETERSEN, W.; HOU, A. Y.; GARCÍA-ORTEGA, E.; MACHADO, L. A. T.; ANGELIS, C. F.; SALIO, P.; KIDD, C.; HUFFMAN, G. J.; CASTRO, M. Global precipitation measurement: Methods, datasets and applications. **Atmospheric Research**, v. 104-105, p. 70–97, fev. 2012. DOI: <https://doi.org/10.1016/j.atmosres.2011.10.021>.
- TRIOLA, M. F. Introdução à Estatística. 12. ed. Rio de Janeiro: LTC, 2017.
- WANG, Y.; XIE, X.; MENG, S.; DANDAN, WU.; CHEN, Y.; JIANG, F.; ZHU, B. Magnitude Agreement Occurrence Consistency, and Elevation Dependency of Satellite-Based Precipitation Products over the Tibetan Plateau. **Remote Sensing**, v. 12, p. 1750, mai. 2020. DOI: <https://doi.org/10.3390/rs12111750>.
- WASSERMAN, L. All of Statistics: A Concise Course in Statistical Inference. 1. ed. New York: Springer New York, 2003.
- WENTZ, F. J.; D. DRAPER. On-orbit absolute calibration of the Global Precipitation Measurement Microwave Imager. *Journal Atmospheric Oceanic Technology*, v. 33, p. 1393-1412, jul. 2016. DOI: <https://doi.org/10.1175/JTECH-D-15-0212.1>.
- XAVIER, A. C.; SCANLON, B. R.; KING, C. W.; ALVES, A. I. New improved Brazilian daily weater gridded data (1961-2020). **International Journal of Climatology**, v. 42, p. 8390-8404, mai. 2022. DOI: <https://doi.org/10.1002/joc.7731>.
- ZHAO, H.; MA, Y. Evaluating the drought-monitoring utility of four satellite-based quantitative precipitation estimation Products at global scale. **Remote Sensing**, v. 11, n. 17, p. 2010, ago. 2019.