

ANÁLISE DA PRECIPITAÇÃO PLUVIOMÉTRICA POR MEIO DE DADOS CHIRPS E GOOGLE EARTH ENGINE

Luiz Pedro de Oliveira Mendes

Universidade Estadual de Montes Claros,
Departamento de Ciências Agrárias, Janaúba, MG, Brasil
luizpedromendes2001@gmail.com

Mariana Rodrigues Magalhães Romeiro

Instituto Federal de Educação Ciência e Tecnologia do Norte de Minas Gerais,
Janaúba, MG, Brasil
magalhaesflorestal@hotmail.com

Lucas Jesus Leal Pimenta

Universidade Estadual de Montes Claros,
Departamento de Ciências Agrárias, Janaúba, MG, Brasil
lucasleal88@hotmail.com

Willer Fagundes de Oliveira

Universidade Estadual de Montes Claros,
Departamento de Ciências Agrárias, Janaúba, MG, Brasil
willer.oliveira@unimontes.br

Silvânio Rodrigues dos Santos

Universidade Estadual de Montes Claros,
Departamento de Ciências Agrárias, Janaúba, MG, Brasil
silvanio.santos@unimontes.br

RESUMO

Neste trabalho foram comparados os dados de precipitação estimados pelo CHIRPS com os dados observados em estações meteorológicas terrestres, utilizando a escala temporal mensal, além de compreender a variabilidade espacial da qualidade dos dados no norte de Minas Gerais. Complementarmente, foi desenvolvida uma rotina computacional utilizando a plataforma *Google Earth Engine* (GEE), para realizar análises espaço-temporal dos dados CHIRPS em escala regional, municipal e, também, em bacias hidrográficas. A extração dos dados CHIRPS foi realizada utilizando as coordenadas geográficas de cada estação terrestre do INMET/ANA, por meio de uma implementação (*script*) no *Google Colab*, obtendo-se os valores das precipitações mensais para o pixel coincidente à geolocalização de cada estação. Ainda no *Google Colab*, foram implementadas métricas comparativas dos dados observados e estimados. Já a rotina desenvolvida (PluvCHIRPS-V1) possui quatro módulos, estruturados por meio de programação orientada a objetos com a linguagem *JavaScript* do GEE. Diante dos resultados encontrados nessa pesquisa e, também, da baixa densidade de estações meteorológicas terrestres na área de estudo, recomenda-se a utilização do CHIRPS como fonte alternativa de dados meteorológicos. A rotina computacional é intuitiva, rápida e automatizada, com grande potencial de análise de séries temporais de precipitação pluviométrica em escala municipal e regional.

Palavras-chave: Climatologia. Sensoriamento remoto. Norte de Minas Gerais. Bacia hidrográfica.

RAINFALL ANALYSIS USING CHIRPS DATA AND GOOGLE EARTH ENGINE

ABSTRACT

The present study compared precipitation data estimated by CHIRPS to data observed at terrestrial meteorological stations, on a monthly temporal scale, and aimed to understand the spatial variability of data quality in the North of Minas Gerais mesoregion. A computer routine was also developed using the *Google Earth Engine* (GEE) platform for spatio-temporal analysis of CHIRPS data on a regional and municipal scale, as well as in watersheds. The CHIRPS data was extracted using the geographic coordinates of each INMET/ANA station, through an implementation (*script*) in *Google Colab*, obtaining the monthly rainfall values for the pixel coinciding with the geolocation of each station. Also in *Google Colab*, metrics were

implemented to compare the observed and estimated data. The routine developed (PluvCHIRPS-V1) has four modules, structured through object-oriented programming with the JavaScript language in the GEE Code Editor. Given the results found and the low density of terrestrial meteorological stations in the study area, the CHIRPS dataset is recommended as an alternative source of meteorological data. The computational routine is intuitive, fast, and automated, with great potential for analyzing rainfall time series at different scales (municipal and regional).

Keywords: Climatology. Remote Sensing. North of Minas Gerais. Watershed.

INTRODUÇÃO

A precipitação pluviométrica é um processo fundamental no ciclo hidrológico e tem papel vital na climatologia (Scheel; Hinnerichsen, 2012; Bai *et al.*, 2018; Rincón-Avalos *et al.*, 2022) e, por isso, tem sido um motivo de preocupação para pesquisadores e climatologistas em todo o mundo (Molla *et al.*, 2022). Medir a precipitação em um determinado local, utilizando instrumentos de superfície (pluviômetro ou pluviógrafo), é relativamente simples. Contudo, apesar de fornecerem excelentes estimativas quando bem manejados, esses instrumentos apresentam limitações na quantidade e no arranjo da distribuição espacial (Rincón-Avalos *et al.*, 2022). Diante dessas limitações, fontes alternativas para a obtenção de dados pluviométricos são sempre bem-vindas.

Com o avanço do sensoriamento remoto, os satélites meteorológicos tornaram-se uma alternativa no processo de medição e monitoramento das variáveis meteorológicas, tanto no âmbito espacial quanto temporal. Essa tecnologia tem contribuído para superar as limitações da observação de precipitação baseada em estações terrestres (Rincón-Avalos *et al.*, 2022). Diversos produtos de estimativa de precipitação pluviométrica, baseados em satélites, foram desenvolvidos nas últimas décadas, como o *Integrated Multi-satellitE Retrievals for GPM* (IMERG), que é um algoritmo que combina informações oriundas da constelação de satélites da *Global Precipitation Measurement Mission* (GPM), que por sua vez é uma missão sucessora do *Tropical Rainfall Measuring Mission* (TRMM), o *Precipitation Estimation From Remotely Sensed Information Using Artificial Neural Networks* (PERSIANN), o ECMWF Reanalysis 5th Generation (ERA5), o *Climate Forecast System Reanalysis* (CFSR), o *Daily Surface Weather Data* (DAYMET) e o *Climate Hazards Group Infrared Precipitation with Stations* (CHIRPS). Dos produtos mencionados, o CHIRPS se destaca como baixa latência, registros longos e melhor resolução espacial (Funk *et al.*, 2015; Costa *et al.*, 2019; López-Bermeo *et al.*, 2022; Rincón-Avalos *et al.*, 2022; Dos Santos *et al.*, 2023).

O CHIRPS é um conjunto de dados de precipitação, com abrangência quase global (50°S-50°N e todas as longitudes), desenvolvido em colaboração com o USGS *Earth Resources Observation and Science* (EROS) *Center*, com o intuito de fornecer informações completas (ininterruptas e atualizadas) e confiáveis de dados de precipitação. Esse *dataset* está disponível em formato matricial (.tif, bil e .netcdf), com resolução espacial de 0,05°, formando uma série histórica atualizada, com registro diário (mm dia⁻¹), desde 1981. Detalhes da metodologia e implementação desse *dataset* podem ser encontrados em Funk *et al.* (2015). Em síntese, os autores combinaram observações de precipitação de estações terrestres (série histórica diária e mensal) com satélites de medição de precipitação, seguido de análises de similaridade e interpolação de dados.

Como, ainda, não há validação em escala regional para toda a área de abrangência do CHIRPS, esse *dataset* tem sido estudado (explorado e validado) em diversas regiões (Tote *et al.*, 2015; Costa *et al.*, 2019; Banerjee *et al.*, 2020; Dubey *et al.*, 2021; López-Bermeo *et al.*, 2022; Molla *et al.*, 2022; Rincón-Avalos *et al.*, 2022; Dos Santos *et al.*, 2023), por meio da comparação de dados coletados na superfície terrestre (pluviômetro e estações meteorológicas), com o intuito de demonstrar o potencial desse *dataset* como uso de dados alternativos. No entanto, verifica-se a necessidade da continuidade desses estudos em diversas escalas (espacial e temporal) para diferentes regiões do planeta, especialmente em regiões com baixa densidade de estações pluviométricas.

Em geral, a utilização (leitura, visualização, processamento e análise) desse *dataset* pode ser feita por meio de 02 maneiras: a) *softwares* tradicionais do Sistema de Informação Geográfica (SIG), tais como ArcGIS®, GRASS, gvSIG, QGIS, SAGA e SPRING; b) plataformas de processamento baseadas na computação em nuvem, como o *Google Earth Engine*® (GEE).

O GEE é uma plataforma de armazenamento, processamento (de alta performance), análise e visualização de dados geoespaciais, criado pela Google® em 2010, a qual utiliza computação em nuvem (com tecnologias *Web*) para o processamento de grandes quantidades de dados de detecção remota. A plataforma GEE permite o acesso, a manipulação e análise em tempo real de grandes volumes de dados geográficos. Por meio do GEE é possível ter acesso a enorme catálogo de dados públicos contendo *petabytes* de imagens de satélite oriundas de múltiplos sensores. Além disso, diariamente, novas imagens são adicionadas ao catálogo, que é acessível gratuitamente a todos os usuários. O GEE é considerado uma plataforma de fácil operação (para profissionais da área de geotecnologia) e que cresceu em popularidade na comunidade de sensoriamento remoto nos últimos anos, contribuindo em diversos estudos da geociência em nível local, regional e global (Ghosh; Kumar; Kumari, 2022). Além desses benefícios, a plataforma pode reduzir significativamente a carga de trabalho no processo de aquisição e processamento de dados (Zhao *et al.*, 2023).

O GEE tem sido utilizado em diversas áreas do conhecimento, com aplicações no mapeamento de uso e ocupação do solo em escala global, mapeamento urbano, incêndios florestais, gestão dos recursos hídricos, mapas de inundação, dentre outros (Tamiminia *et al.*, 2020). Uma das grandes vantagens do GEE é a facilidade do uso e compartilhamento de rotinas computacionais (*scripts*) e *apps*, desenvolvidos para uma determinada aplicação, sem a necessidade de o usuário ser um “*expert*” em programação *web* (Gorelick *et al.*, 2017; Tamiminia *et al.*, 2020). Em vista disso, algumas rotinas de geoprocessamento são personalizadas, novos algoritmos são criados, alguns aperfeiçoados, todos para automatizar ao máximo qualquer tarefa (*workflow*). Essa automatização de processos, para análises de imagens de satélites, tem sido uma tendência global, pois, além de reduzir o processamento manual dispendioso e demorado, propicia uma abordagem sistemática para fornecer mapas temáticos robustos e precisos (Ghosh; Kumar; Kumari, 2022).

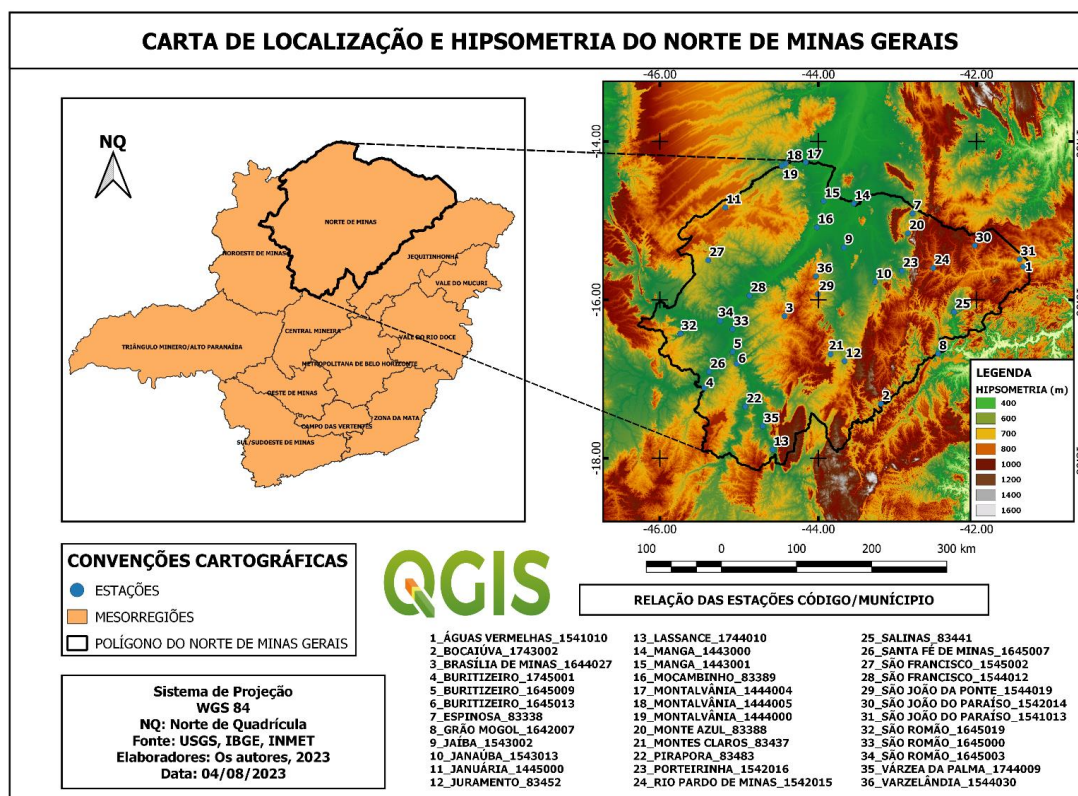
Nesse contexto, instigado pela tendência de processamento de dados em nuvem (em tempo “quase real”) e, também, por busca de dados alternativos (de qualidade e ininterruptos) de precipitação pluviométrica para gestão dos recursos hídricos, objetivou-se comparar os dados de precipitação estimados pelo CHIRPS com os dados observados em estações meteorológicas terrestres, em escala temporal mensal, bem como compreender a variabilidade espacial da qualidade dos dados na mesorregião do norte de Minas Gerais. Complementarmente, desenvolveu-se uma rotina computacional utilizando a plataforma GEE, para realizar análises espaço-temporal dos dados CHIRPS em escala regional, municipal e, também, em bacias hidrográficas.

METODOLOGIA

Área de estudo

Selecionou-se a mesorregião do norte de Minas Gerais (Figura 1), formada por 89 municípios (área aproximada de 128.368,30 km²) com características singulares no aspecto social, cultural, econômico e geográfico. Essa região se mostra vulnerável frente às mudanças climáticas (Freitas; Calheiros; Dos Reis, 2019) e o abastecimento dos recursos hídricos fica condicionado à frequência das zonas de Convergência do Atlântico Sul (ZCAS) e da Zona de Convergência de Umidade (ZCOU). As zonas de convergência ocorrem durante a primavera e verão; sua intensidade e frequência são influenciadas pelo fenômeno El Niño Oscilação Sul (ENOS). Também se caracteriza como uma região de transição entre o úmido e o semiárido, o florestal e o de vegetações abertas (cerrados, campos cerrados, caatingas, matas secas e campos de altitude), com relevo montanhoso e de superfícies aplainadas (Carneiro, 2003).

Figura 1 - Mesorregião do norte de Minas Gerais: Localização, hipsometria e distribuição espacial das estações meteorológicas terrestres utilizadas na validação dos dados CHIRPS, 2023



Fontes: IBGE, 2022; INMET, 2023; USGS/SRTM, 2018. Elaboração: Os autores, 2023.

Para efeito de demonstração da aplicabilidade da rotina computacional em bacias hidrográficas, utilizou-se o polígono da Área de Drenagem da Barragem do Bico da Pedra (ADBBP), também, situada na mesorregião do norte de Minas Gerais, permeando os municípios de Janaúba (13,95%), Francisco Sá (35,56%), Riacho dos Machados (29,09%) e Porteirinha (21,40%), totalizando uma área aproximada de 1.629,40 km².

Conjunto de dados remotos e terrestres

Para os dados remotos, utilizaram-se os registros diários (mm/day) do CHIRPS *Daily* (Version 2.0 Final), com resolução espacial de 0,05° (aproximadamente 5,5 km) e com o período homólogo ao das estações terrestres do Instituto Nacional de Meteorologia (INMET) e da Agência Nacional de Águas (ANA). Para os dados terrestres, foram utilizadas informações diárias observadas de precipitação, oriundas de estações meteorológicas/pluviômetros, sendo 32 da ANA e 8 do INMET (Figura 1 e Tabela 1).

Os dados terrestres, coletados entre os anos de 1981 a 2022, foram submetidos à análise e remoção de falhas. Bai *et al.* (2018) excluíram do banco de dados as estações que apresentaram mais de um ano de falha na série histórica de 36 anos. Já López-bermeo *et al.* (2022) descartaram as estações com mais de 10% de falhas diárias, para uma série histórica de 38 anos. No entanto, pela quantidade de estações/pluviômetros no norte de Minas Gerais, optou-se por excluir os meses que apresentaram mais de 20% de falhas diárias em cada estação terrestre (pluviômetro). Em seguida, obteve-se a precipitação total mensal ao longo dos anos, com uma série histórica mínima de 30 anos, com exceção da estação de Mocambinho (código 83389), com 29 anos.

Tabela 1 - Mesorregião do norte de Minas Gerais: relação das estações meteorológicas selecionadas para validação, 1981 a 2022

Município	Código	Série histórica	Anos - série histórica	Meses de falhas	Anos (completos) de falhas	Latitude	Longitude	Responsável
Águas Vermelhas	1541010	1981 a 2022	41	11	0	-15°34'51"	-41°24'31"	ANA
Bocaiúva	1743002	1981 a 2022	41	0	0	-17°18'46"	-43°12'28"	ANA
Brasília de Minas	1644027	1981 a 2021	40	14	0	-16°12'23"	-44°25'31"	ANA
Buenópolis	1744030	1983 a 2021	38	5	0	-17°59'43"	-44°10'36"	ANA
Buritizeiro	1645009	1981 a 2022	41	9	0	-16°39'24,8"	-45°04'50,8"	ANA
Buritizeiro	1645013	1981 a 2022	41	6	0	-16°48'25,9"	-45°01'49"	ANA
Buritizeiro	1745001	1981 a 2021	39	15	1	-17°06'39,9"	-45°26'16"	ANA
Espinosa	83338	1981 a 2018	37	37	0	-14°54'43,9"	-42°48'30,9"	INMET
Grão Mogol	1642007	1981 a 2022	41	1	0	-16°40'44"	-42°29'08,1"	ANA
Jaíba	1543002	1981 a 2022	41	6	0	-15°20'27,9"	-43°40'31"	ANA
Janaúba	1543013	1981 a 2022	41	3	0	-15°46'32,1"	-43°16'46,9"	ANA
Januária	83386	1981 a 2021	39	28	1	-15°26'52,8"	-44°21'58,6"	INMET
Januária	1445000	1981 a 2022	41	14	0	-14°50'09,9"	-45°10'23,8"	ANA
Juramento	83452	1987 a 2020	33	4	0	-16°46'30"	-43°40'01,2"	INMET
Lassance	1744010	1981 a 2021	40	14	0	-17°53'24"	-44°34'36,1"	ANA
Manga	1444003	1981 a 2022	41	3	0	-14°44'51"	-44°24'39,9"	ANA
Manga	1443001	1981 a 2019	38	1	0	-14°45'24,1"	-43°55'55,9"	ANA
Mocimbo	83389	1981 a 2012	29	34	2	-15°05'09,6"	-44°00'58,3"	INMET
Montalvânia	1444000	1981 a 2022	41	1	0	-14°18'48,9"	-44°27'37"	ANA
Montalvânia	1444005	1981 a 2022	41	19	0	-14°16'50,1"	-44°24'33,8"	ANA
Montalvânia	1444001	1981 a 2021	40	1	0	-14°25'51,9"	-44°28'54,1"	ANA
Montalvânia	1444004	1981 a 2021	40	0	0	-14°15'56,8"	-44°09'25,9"	ANA
Monte Azul	83388	1981 a 2015	34	14	1	-15°09'37"	-42°51'58,6"	INMET
Montes Claros	83437	1981 a 2021	39	23	1	-16°41'10,6"	-43°50'37,6"	INMET
Pirapora	83483	1981 a 2019	37	25	1	-17°20'56,7"	-44°55'17,7"	INMET
Porteirinha	1542016	1983 a 2022	39	2	0	-15°38'12,1"	-42°56'36,9"	ANA
Rio Pardo de Minas	1542015	1981 a 2022	41	5	0	-15°35'53,8"	-42°32'51"	ANA
Salinas	83441	1981 a 2021	39	19	1	-16°09'17,2"	-42°17'05,6"	INMET
Santa Fé de Minas	1645007	1981 a 2021	39	68	1	-16°54'32,04"	-45°22'42,9"	ANA
São Francisco	1544012	1981 a 2022	41	1	0	-15°56'57,8"	-44°52'5,1"	ANA
São Francisco	1545002	1981 a 2020	37	63	2	-15°30'7,9"	-45°23'24"	ANA

São João da Ponte	1544019	1981 a 2022	41	24	0	-15°55'49"	-44°00'15,1"	ANA
São João do Paraíso	1542014	1981 a 2022	46	14	0	-15°19'0,1"	-42°01'22"	ANA
São João do Paraíso	1541013	1985 a 2022	37	7	0	-15°29'22,9"	-41°27'28"	ANA
São Romão	1645000	1981 a 2022	41	1	0	-16°22'18,1"	-45°04'58"	ANA
São Romão	1645003	1981 a 2022	40	23	1	-16°16'06,9"	-45°14'16"	ANA
São Romão	1645019	1984 a 2022	38	21	0	-16°25'42,9"	-45°44'31,9"	ANA
São Romão	1645002	1981 a 2021	40	13	0	-16°16'54,1"	-45°24'51,1"	ANA
Várzea da Palma	1744009	1981 a 2022	41	4	0	-17°35'45,9"	-44°42'03,9"	ANA
Varzelândia	1544030	1983 a 2022	39	9	0	-15°42'15,1"	-44°,7042	ANA

Fontes: ANA, 2022; INMET, 2022. Elaboração: Os autores, 2023.

Análise dos dados

A extração dos dados oriundos do CHIRPS foi realizada com base nas coordenadas geográficas de cada estação/pluviômetro terrestre do INMET/ANA. Para isso, foi desenvolvida uma rotina computacional no Google Colab, utilizando as bibliotecas *datatime*, *geopandas*, *glob*, *matplotlib*, *os*, *pandas* e *rasterio*, a qual se obtiveram os valores das precipitações diárias, no período considerado, para o pixel coincidente à geolocalização de cada estação apresentada na Tabela 1. Ainda no Google Colab, utilizando as bibliotecas *csv*, *numpy*, *pandas*, *scipy.stats* e *sklearn.metrics*, calculou-se a precipitação mensal, aplicando-se, em seguida, as métricas comparativas *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE) e coeficiente de correlação de Pearson (r) (eq. 1, 2 e 3).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \quad (1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - O_i| \quad (2)$$

$$r = \frac{\sum_{i=1}^n (P_i - \bar{P})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (P_i - \bar{P})^2 \cdot \sum_{i=1}^n (O_i - \bar{O})^2}} \quad (3)$$

em que (P_i) e (O_i) representam, respectivamente, o modelo predito (CHIRPS) e o valor observado (INMET/ANA). O número de amostra na série temporal é representado por (n) e \bar{P} e \bar{O} correspondem às médias dos valores preditos e observados, respectivamente.

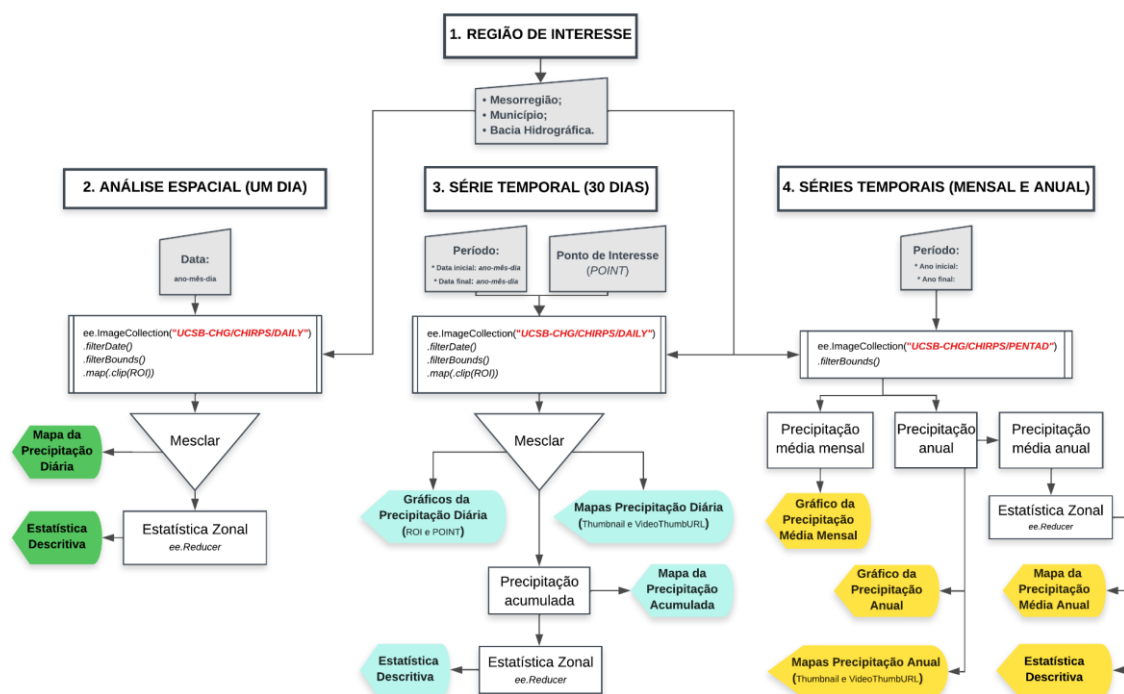
Por último, para melhor compreensão e visualização da variabilidade espaço-temporal, os mapas temáticos das métricas supracitadas foram gerados utilizando o interpolador *Inverse Distance Weighted* (IDW) no *software* QGIS versão 3.22.

Implementação da rotina computacional

A rotina desenvolvida, denominada PluvCHIRPS-V1, possui quatro módulos (Figura 2), estruturados por meio de programação orientada a objetos (funções) com a linguagem JavaScript no *Code Editor* do GEE. Para o desenvolvimento dos *scripts*, utilizaram-se os seguintes métodos (ou construtores) do *Earth Engine*: *Chart* (ui.Chart), *Date* (ee.Date), *Dictionary* (ee.Dictionary), *Geometry* (ee.Geometry),

Image (ee.Image), *ImageCollection* (ee.ImageCollection), *Number* (ee.Number), *Reducer* (ee.Reducer) e *String* (ee.String).

Figura 2 - Mesorregião do norte de Minas Gerais: *Workflow* da rotina desenvolvida (PluvCHIRPS-V1), com quatro módulos (1. REGIÃO DE INTERESSE, 2. ANÁLISE ESPACIAL (UM DIA), 3. SÉRIE TEMPORAL (30 DIAS) e 4. SÉRIES TEMPORAIS – MENSAL E ANUAL). Os trapézios cinzas representam os *inputs*, os retângulos brancos representam os algoritmos e os demais polígonos (coloridos) são os *outputs*, 2023



Fonte: Os autores, 2023.

O primeiro módulo (1. REGIÃO DE INTERESSE) foi desenvolvido para o usuário definir uma região de interesse (ROI) como variável (“var”). Nesse módulo, o usuário delimitará ou importará um polígono (*geometry*) que representa a área de estudo (mesorregião do norte de Minas Gerais, município, bacia hidrográfica ou outro polígono de interesse), a qual será utilizada nos módulos subsequentes, especificamente, no filtro “*filterBounds*”, na função recortar [*.map(.clip)*], na estatística zonal e no limite do mapeamento.

O segundo módulo (2. ANÁLISE ESPACIAL – UM DIA) consiste em realizar uma análise espacial da precipitação diária (mm dia⁻¹) de um único dia. Para isso, é necessário que o usuário informe, apenas, a data de interesse (‘ano-mês-dia’) e uma das ROIs definida no módulo anterior. As imagens disponíveis são oriundas do catálogo CHIRPS *Daily*, especificamente, da coleção “*UCSB-CHG/CHIRPS/DAILY*”. Durante o processo de consulta, são aplicados filtros de data, limite e recorte da área de interesse. Na sequência, é realizada a estatística zonal, calculando os valores de precipitação máxima, mínima, desvio-padrão, histograma e quantidade de *pixels* analisados. Por último, o Mapa da Precipitação Diária, com legenda, é apresentado no “*Map do GEE*”, acompanhado da estatística zonal descritiva, apresentada no console.

O terceiro módulo (3. SÉRIE TEMPORAL – 30 DIAS) consiste em realizar uma análise espacial e temporal da precipitação diária (mm dia⁻¹), seguido da estatística zonal da precipitação acumulada para o intervalo definido. Para esse propósito, exige-se que o usuário defina um período de interesse (data inicial e final), uma ROI e um ponto de interesse (*POINT*) como variável (“var”), sendo esse último, caso o usuário tenha interesse de estimar a precipitação e um ponto (*pixel*) específico, ou seja, sem contemplar a espacialização dos dados. Pela capacidade máxima de processamento em nuvem ser

limitada, para um usuário cadastrado (sem custo) no GEE e, também, para o tamanho da área da ROI (mesorregião do norte de Minas Gerais), o período de análise nesse módulo limita-se, em média, a 30 dias. Ressalta-se que, o número de dias pode aumentar à medida que o tamanho da ROI diminui. O presente módulo, também, utiliza as imagens da coleção “UCSB-CHG/CHIRPS/DAILY”, bem como os mesmos filtros do módulo anterior. Os mapas da análise espaço-temporal da precipitação diária para ROI são apresentados na forma de mapas dinâmicos (*Timelapse*) no console, utilizando as funções “*ui.Thumbnail*” e “*getVideoThumbURL*”. Na sequência, são apresentados dois gráficos da precipitação diária, o primeiro é a precipitação média diária no interior da ROI e, o segundo, a precipitação diária para um único ponto específico (*POINT*). Também, é contabilizada a precipitação acumulada, com cálculo da estatística zonal para ROI. Por último, é apresentado o mapa da precipitação acumulada, acompanhado da estatística zonal descritiva, apresentada no console do GEE.

O quarto e último módulo (4. SÉRIES TEMPORAIS – MENSAL E ANUAL) consiste em realizar uma análise espacial e temporal da precipitação média mensal e anual, de acordo com o período definido pelo usuário. Para tanto, o usuário precisa definir, obrigatoriamente, o período de análise (ano inicial e final) e a ROI. Com base nessas informações, as imagens da coleção “UCSB-CHG/CHIRPS/PENTAD” são acessadas. Na sequência, é calculada a precipitação média mensal, a precipitação anual e a precipitação média anual entre os anos selecionados, apresentando respectivamente os seguintes produtos: gráfico da precipitação média mensal, gráfico da precipitação anual e mapas dinâmicos da precipitação anual, bem como um mapa da precipitação média anual, acompanhado da estatística zonal descritiva.

RESULTADOS E DISCUSSÃO

Comparação dos dados remotos e terrestres

Os meses de maio a setembro apresentaram menores variações da raiz do erro quadrático médio (RMSE) entre os valores preditos de precipitação a partir do modelo CHIRPS e os observados nas estações meteorológicas (Figura 3), destacando-se os meses de junho a agosto. Tal verificação já era esperada, uma vez que durante o outono e inverno a precipitação é significativamente reduzida no norte do Estado de Minas Gerais, em razão da diminuição da dinâmica atmosférica na região (redução da intensidade da irradiação solar), corroborando com os valores encontrados por Costa *et al.* (2019) e Silva *et al.* (2020) em outras regiões do Brasil na análise do RMSE durante o período seco.

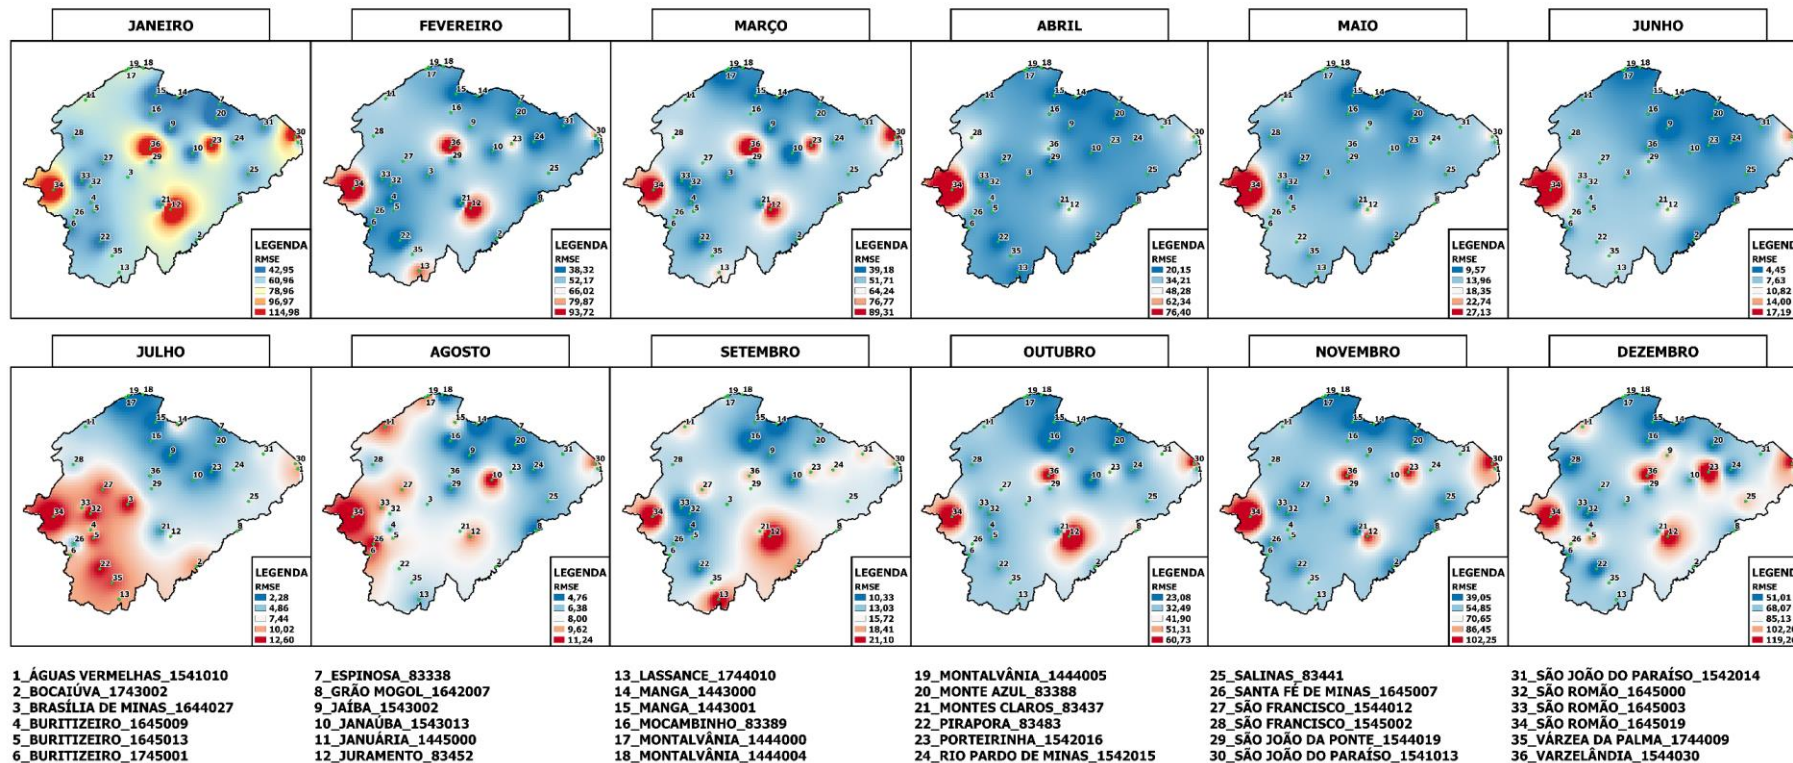
Observou-se, também, nos meses de abril, maio e junho pequenas áreas com valores de RMSE acima de 9,0 (Figura 3). Já os meses de junho, julho e setembro apresentaram maiores áreas com valores acima de 9,0, destacando-se o mês de julho. Os menores valores de RMSE encontrados foram nos meses de junho, julho e agosto com 4,45, 2,28 e 4,76, respectivamente. Costa *et al.* (2019) também encontraram valores abaixo de 5,0 para os meses de junho a agosto.

Os resultados do erro absoluto médio (MAE) para os meses de abril, maio e junho apresentaram o mesmo padrão observado nos resultados do RMSE, (Figura 4 e Figura 3). Mesmo trabalhando com uma série histórica acima de 29 anos, observou-se uma amplitude considerável dos valores de MAE e RMSE durante a estação chuvosa. Essa verificação pode ser explicada pela interferência de eventos como o ENOS (El Niño-Oscilação Sul) que influencia na intensificação/redução de ZCAS – Zona de Convergência do Atlântico Sul (Vásquez *et al.*, 2018), que ocorre apenas durante a primavera e verão (estação chuvosa na área estudada). A ZCAS é responsável pela recarga hídrica da região Norte de Minas Gerais.

Entre os meses de outubro a março (meses com maiores volumes de precipitação), as correlações foram maiores quando comparadas aos meses com menor precipitação, ou seja, os meses entre maio a setembro apresentaram correlações inferiores, sendo julho o mês com maior área (km²) de baixa correlação (Figura 5). Destacaram-se os meses de janeiro e dezembro com maiores correlações, ou seja, valores máximos de $r = 0,93$ e $r = 0,91$, respectivamente. Costa *et al.* (2019) também encontraram valores acima de $r = 0,90$ para os meses de dezembro e janeiro para a região Sudeste do Brasil.

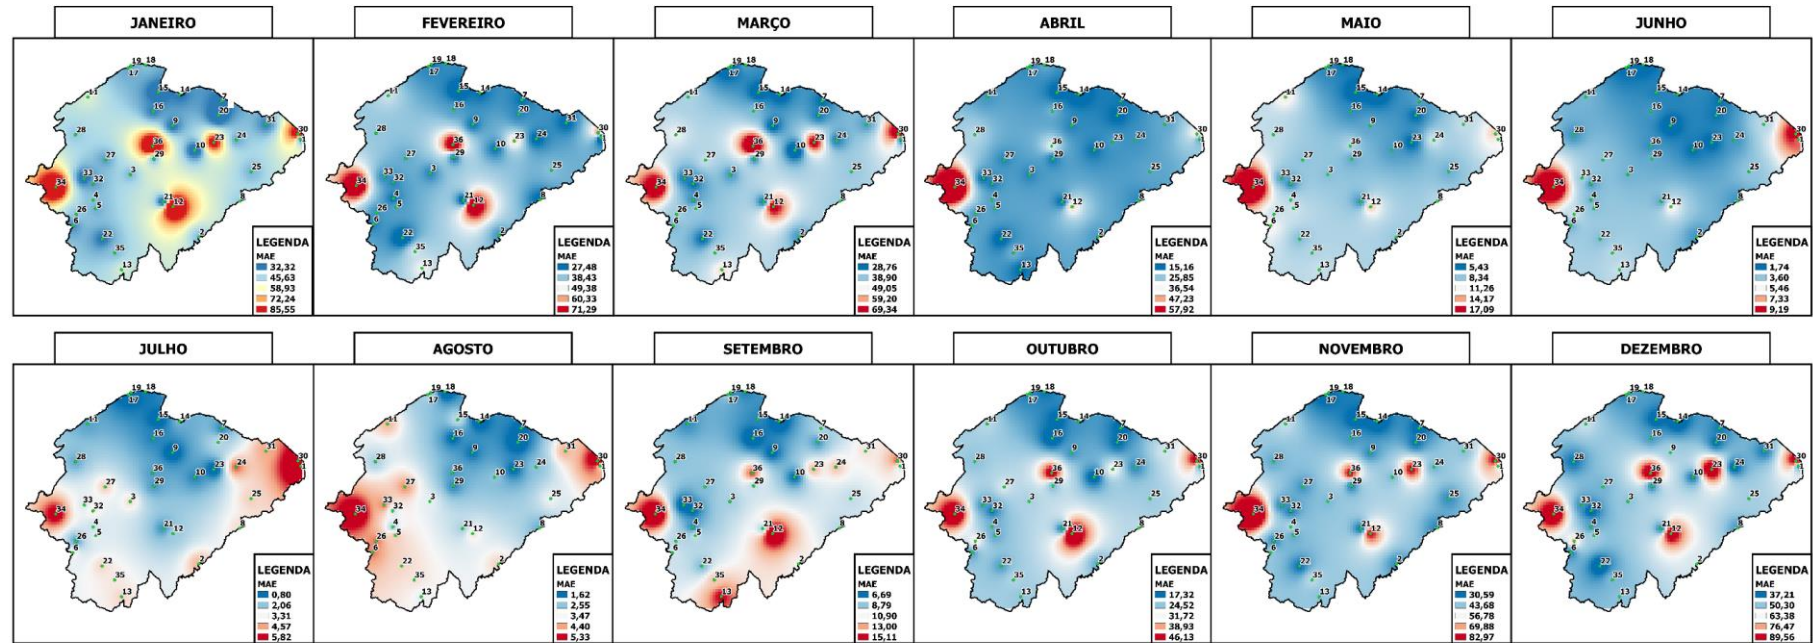
De acordo com Grimm e Sant’anna (2000), algumas regiões do Brasil possuem clima de muitos contrastes nos regimes de precipitação e temperatura, pela localização geográfica e pelas formações geomorfológicas. Para Santos *et al.* (2023), eventos de baixa intensidade de precipitação tendem a ser superestimados pelo modelo CHIRPS, nesse período; o contrário ocorrendo com os de alta intensidade. Já Rivera, Marianetti e Hinrichs (2018) constataram diferenciação na precisão de acordo com o período e a localização dos pontos avaliados em estudos realizados na Argentina.

Figura 3 - Mesorregião do norte de Minas: variabilidade espacial mensal do *Root Mean Squared Error* (RMSE) das precipitações previstas pelo modelo CHIRPS e observadas em estações meteorológicas, 1981 a 2022



Fonte: Os autores, 2023.

Figura 4 - Mesorregião do norte de Minas Gerais: variabilidade espacial mensal do Mean Absolute Error (MAE) de precipitações preditas pelo modelo CHIRPS e observadas em estações meteorológicas, 1981 a 2022



1_ ÁGUAS VERMELHAS_1541010
 2_ BOCAIÚVA_1743002
 3_ BRASÍLIA DE MINAS_1644027
 4_ BURITIZZEIRO_1645009
 5_ BURITIZZEIRO_1645013
 6_ BURITIZZEIRO_1745001

7_ ESPINOSA_83338
 8_ GRÃO MOGOL_1642007
 9_ JAÍBA_1543002
 10_ JANAÚBA_1543013
 11_ JANUÁRIA_1445000
 12_ JURAMENTO_83452

13_ LASSANCE_1744010
 14_ MANGA_1443000
 15_ MANGA_1443001
 16_ MOCAMBINHO_83389
 17_ MONTALVÂNIA_1444000
 18_ MONTALVÂNIA_1444004

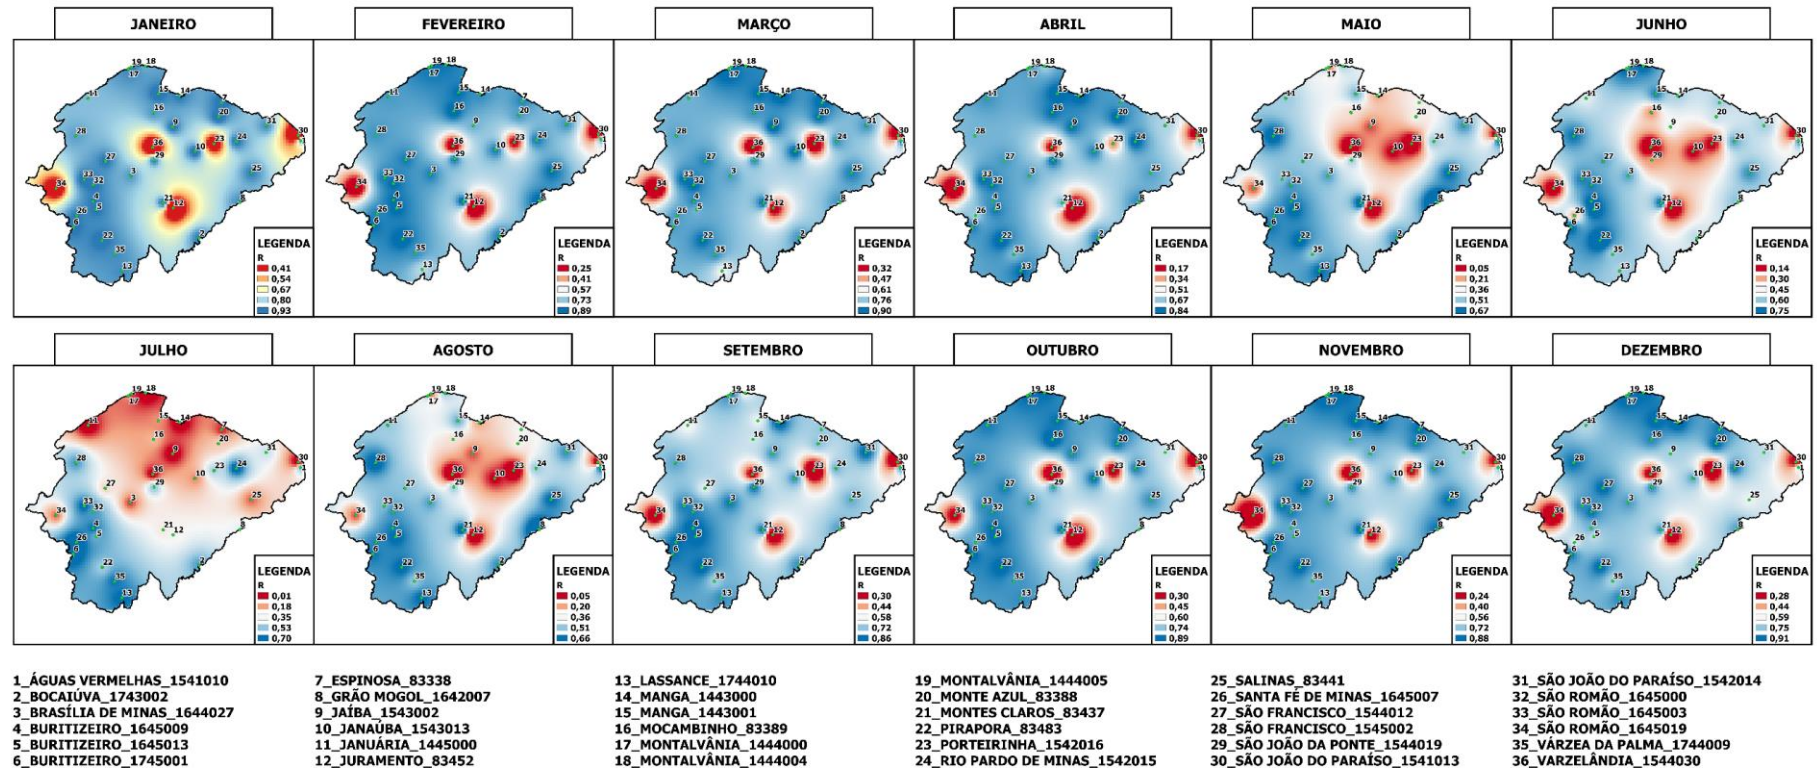
19_ MONTALVÂNIA_1444005
 20_ MONTE AZUL_83388
 21_ MONTES CLAROS_83437
 22_ PIRAPORA_83483
 23_ PORTEIRINHA_1542016
 24_ RIO PARDO DE MINAS_1542015

25_ SALINAS_83441
 26_ SANTA FÉ DE MINAS_1645007
 27_ SÃO FRANCISCO_1544012
 28_ SÃO FRANCISCO_1545002
 29_ SÃO JOÃO DA PONTE_1544019
 30_ SÃO JOÃO DO PARAÍSO_1541013

31_ SÃO JOÃO DO PARAÍSO_1542014
 32_ SÃO ROMÃO_1645000
 33_ SÃO ROMÃO_1645003
 34_ SÃO ROMÃO_1645019
 35_ VÁRZEA DA PALMA_1744009
 36_ VARZELÂNDIA_1544030

Fonte: Os autores, 2023.

Figura 5 - Mesorregião do norte de Minas Gerais: variabilidade espacial mensal do coeficiente de correlação de Pearson (r) entre resultados de precipitações preditas pelo modelo CHIRPS e observadas em estações meteorológicas, 1981 a 2022



Fonte: Os autores, 2023.

Entre os meses de maio a setembro, os resultados das análises apresentaram menores discrepâncias do CHIRPS em relação aos dados coletados em solo, quando comparados aos demais meses, pela redução da dinâmica atmosférica durante as estações outono e inverno. Durante a primavera e verão, ocorrem as zonas de convergências e o volume precipitado é maior em relação às outras estações. Para aumentar a confiabilidade dos resultados dos estudos de precipitação, são necessárias qualidade dos dados coletados e ampla distribuição espacial (Costa *et al.*, 2012). Como apresentado (Figura 1), a mesorregião do norte de Minas Gerais possui baixa densidade de estações meteorológicas terrestres.

A baixa densidade da rede de pluviômetros no Brasil e as falhas nas séries de dados dificultam o monitoramento das chuvas (Mello *et al.*, 2017; Ruezzena *et al.*, 2021; Gomes *et al.*, 2022). A confiabilidade dos dados é de extrema importância, uma vez que vários municípios da região estudada possuem o agronegócio como principal atividade econômica. Nesse sentido, maiores investimentos para densificação dessa rede meteorológica se fazem necessários, pois a ausência de dados pode gerar dificuldades, dúvidas ou imprecisão em análises envolvendo dados de precipitação (Baba; Vaz; Costa, 2014).

Em alguns casos, a área coberta por uma única estação terrestre torna-se excessivamente grande e isso, certamente, reduz o nível de representatividade das variáveis meteorológicas (Rincón-Avalos *et al.*, 2022), ou seja, há redução de escala. A mesorregião do norte de Minas Gerais (Figura 1), composta por 89 municípios, possui apenas 40 estações/ pluviômetros (ANA/INMET) com mais de 29 anos de dados meteorológicos.

A precipitação é uma das variáveis climatológicas mais importantes na determinação das condições climáticas locais, exercendo influência em diversas áreas como a modulação de estações chuvosas e secas (Silva *et al.*, 2019; Silva *et al.*, 2020). Desta forma, é de suma importância para estudos climáticos e hidrológicos obtermos dados de qualidade (Fisch; Marengo; Nobre, 1998). Em geral, a chuva medida em superfície (pluviômetros) é considerada como o valor real, uma vez que é a medida direta da chuva que efetivamente atinge uma determinada superfície, e é utilizada como fonte primária para validação de outros métodos de medida e/ou estimativa de chuva (Kidd *et al.*, 2020).

O monitoramento da influência de mecanismos climáticos na precipitação torna-se imprescindível como componente de análise para melhor planejamento e gestão dos recursos hídricos com enfoque na sustentabilidade hídrica com finalidade de haver maior manutenção do equilíbrio entre oferta e demanda (Rocha; Lima, 2020; Reboita *et al.*, 2021; Espinoza *et al.*, 2022). Em um cenário de instabilidade constante no regime hídrico pelas mudanças climáticas, quanto maior a quantidade de informações sobre as variáveis climáticas, maior a possibilidade de redução dos danos.

Vários são os fatores que influenciam a resposta dos sensores de satélite para capturar a precipitação na região específica, o que significa que as análises regionais são igualmente importantes (López-Bermeo *et al.*, 2022). A tendência de superestimar ou subestimar os valores de precipitação está condicionada pelas características morfoclimáticas e cobertura do solo da região (Shrestha *et al.*, 2017; Baez-Villanueva *et al.*, 2018; López-Bermeo *et al.*, 2022), pois tais características influenciam a radiação, a termodinâmica, a física da nuvem e isso pode variar de uma região para outra (Palharini *et al.*, 2021).

Os dados do CHIRPS são importantes pela significativa cobertura temporal e resolução espacial (Bai *et al.*, 2018). A caracterização espaço-temporal é fundamental para o entendimento da padronização, mudanças de intensidade e frequência da variabilidade pluviométrica (Silva Neto *et al.*, 2020; Melo; Lima, 2021). Na mesorregião do norte de Minas Gerais, o CHIRPS apresenta-se como importante ferramenta para auxiliar nas tomadas de decisões em diversas áreas como a agrícola, construção civil, defesa civil e saneamento. Paca *et al.* (2020) relataram a eficiência do conjunto de dados CHIRPS para a bacia hidrográfica do rio Amazonas. No entanto, para cenários de anos extremos, Gomes *et al.* (2022) encontraram tendências de superestimação dos dados CHIRPS para a bacia hidrográfica do rio Guamá-PA.

Desempenho e funcionalidades da rotina computacional

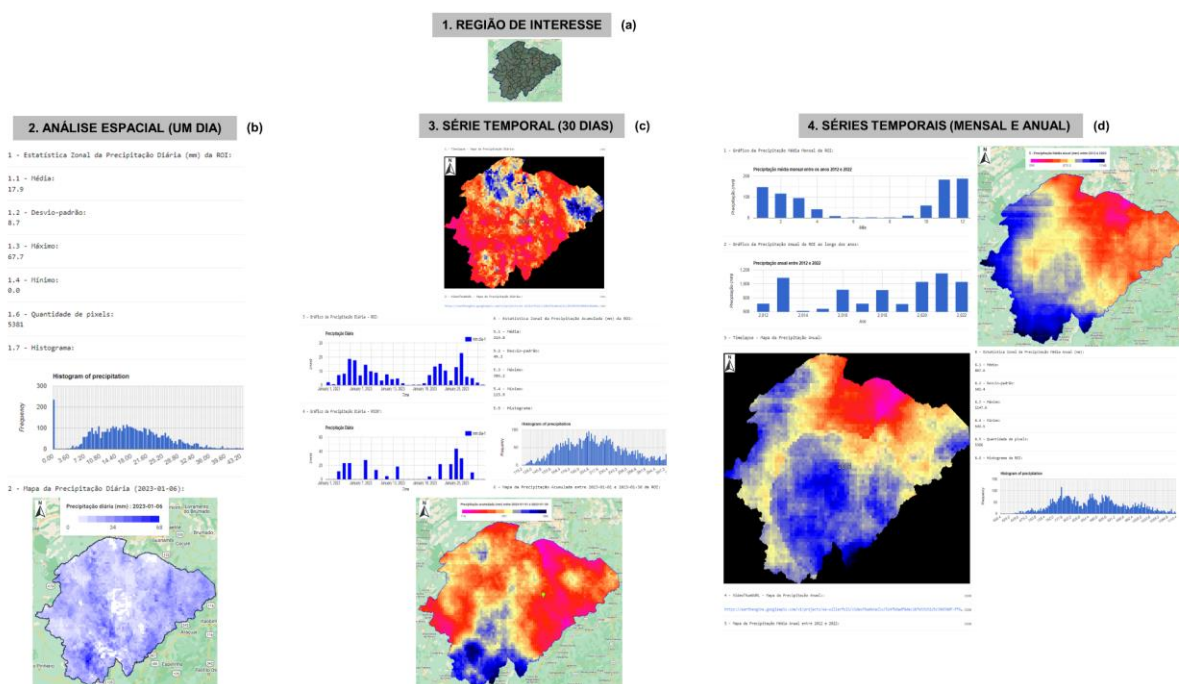
Em relação à rotina desenvolvida, é importante ressaltar que não exige interferência do usuário para configuração de parâmetros (100% automatizada), exige apenas que o analista informe (*inputs*) a região (ROI), um ponto (*POINT*), a data (ano-mês-dia) e o período (ano inicial e final) de interesse. Caso o usuário deseje importar (e analisar) outra ROI, essa deve estar na extensão *shapefile* (.shp) e,

assim, poderá ser adicionada no GEE por meio da opção “*Asset-Table Upload*” e, posteriormente, definida como uma variável (“var”) no primeiro módulo. Ressalta-se que o primeiro módulo é apenas para importação, definição (com variável) e visualização (Figura 6-A) das regiões de interesse (ROIs); nos demais módulos acrescentam-se as análises espaço-temporal.

O segundo módulo (Figura 6-B) será útil quando o usuário tiver conhecimento do dia da ocorrência da precipitação no interior da ROI. Nesse módulo, além de permitir compreender a variabilidade espacial da precipitação diária, também permite extrair a magnitude desse evento por meio das métricas básicas da estatística descritiva. O conhecimento da distribuição espacial da precipitação é a base para compreender as mudanças climáticas regionais, otimizar a gestão dos recursos hídricos e, conseqüentemente, melhorar a capacidade de lidar com desastres naturais como secas e inundações (Hu *et al.*, 2019; Rincón-Avalos *et al.*, 2022).

Já no terceiro módulo (Figura 6-C) foi acrescentada a análise temporal, permitindo o usuário compreender a variabilidade espacial ao longo dos dias. Esse tipo de análise, certamente, contribuiu para melhor compreensão da dinâmica atmosférica e, também, como uma alternativa de grande potencial para analisar séries temporais de precipitação diária para regiões que não possuem dados pluviométricos, bem como para preencher lacunas desses dados (Paca *et al.*, 2020; Dos Santos *et al.*, 2023). Caso o usuário utilize a mesorregião do norte de Minas Gerais como ROI, recomenda-se adotar um período máximo de 30 dias. Para ROI com escala maior (01 município ou 01 bacia hidrográfica como a da área de drenagem da barragem do Bico da Pedra (ADBBP), certamente, o usuário poderá aumentar o período de análise. A limitação do período e da escala está diretamente relacionada com a quantidade de volume de dados demandados para processamento na plataforma GEE. Alguns erros de escala (*scaling errors*) podem ocorrer quando o volume de saída de dados é muito grande, aumentando o tempo de processamento. Esses erros são conhecidos no GEE e estão associados à paralelização e execução dos cálculos, como erro de serviço interno, tempo limite de cálculo esgotado, limite de memória do usuário excedido e muitas agregações simultâneas (Tamiminia *et al.*, 2020). Como é de conhecimento, para ROI com escala menor (micro e mesorregião) a magnitude da variabilidade espacial da precipitação, certamente, será mais significativa. Nesse sentido, pode ser interessante para o analista obter a magnitude da precipitação para um único ponto. Para isso, basta definir o ponto de interesse (*POINT*) como variável.

Figura 6 - Mesorregião do norte de Minas Gerais: produtos gerados pela rotina PluvCHIRPS-V1, 2023

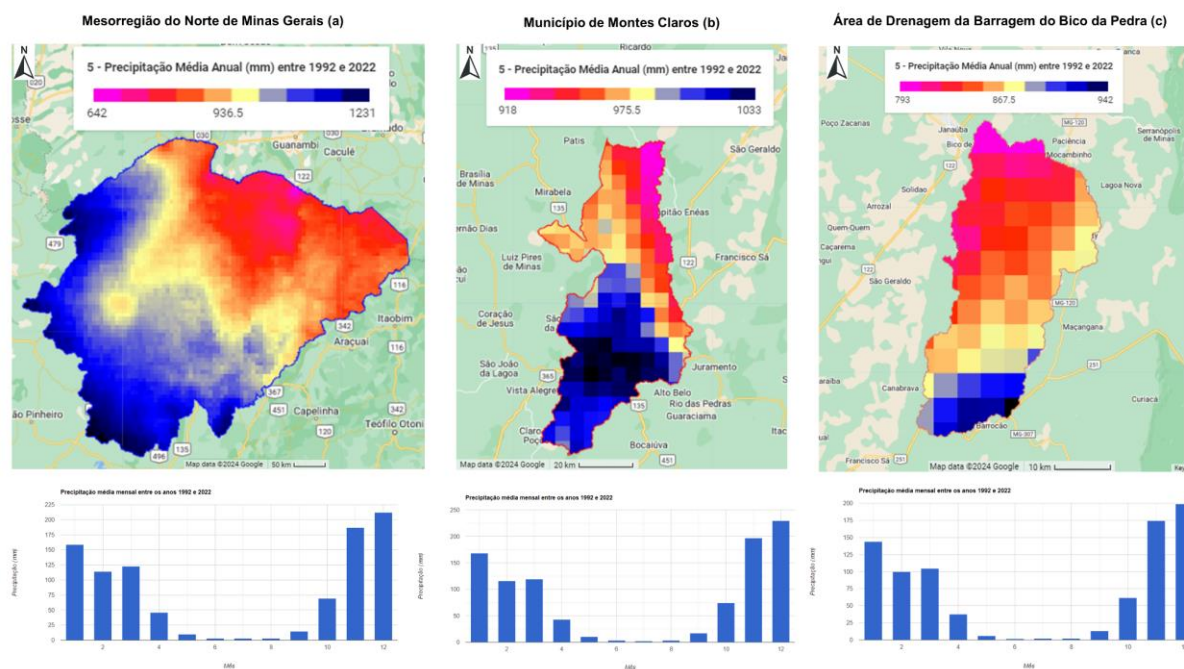


Fonte: Os autores, 2023.

Em algumas situações, a análise da precipitação mensal e anual bem como a variabilidade da precipitação acumulada anual poderão ser de interesse do analista. Para o desenvolvimento científico abrangente, especialmente, para avaliação do balanço hídrico e formulação de políticas públicas, é importante ter conhecimento detalhado do desempenho típico da precipitação para compreender o padrão de distribuição das chuvas em várias estações ao longo do ano (Dubey *et al.*, 2021). Nessas condições, recomenda-se utilizar o quarto módulo (Figura 6-D), o qual é semelhante ao módulo anterior; apresenta os mapas no formato dinâmico (*timelapse*) para facilitar a compreensão dos dados, bem como os gráficos de precipitação média mensal e anual, além da estatística zonal descritiva.

O estudo apresenta uma característica muito relevante, que é a aplicabilidade e escalabilidade da rotina PluvCHIRPS-V1 na gestão de recursos hídricos, considerando que a rotina foi validada para a mesorregião do norte de Minas Gerais, onde informações de precipitação pluviométrica são escassas e, quando existente, os dados possuem elevadas falhas. Os produtos gerados, por meio da rotina, poderão ser usados para estudar e compreender a dinâmica espacial e temporal da precipitação, bem como para analisar o impacto no uso da terra, na população e no ambiente, em diferentes escalas geoespaciais (Figura 7).

Figura 7 - Mesorregião do norte de Minas Gerais (a), Montes Claros (b) e área de drenagem da barragem do Bico da Pedra (c): Produtos gerados em diferentes escalas pela rotina PluvCHIRPS-V1 (módulo 4-SÉRIES TEMPORAIS – MENSAL E ANUAL), 1992 e 2022



Fonte: Os autores, 2023.

Considerando o período de análise entre os anos de 1992 e 2022, a mesorregião do norte de Minas Gerais possui variabilidade espacial da precipitação média anual bem significativa ($\hat{x} = 944,1$ mm e $\sigma = \pm 120,6$ mm), com valores médios que podem variar de 642,4 mm a 1.231,5 mm (Figura 7-A). Já em escala municipal, a exemplo de Montes Claros, a magnitude da variabilidade é bem menor ($\hat{x} = 985,2$ mm e $\sigma = \pm 30,7$ mm), ou seja, com valores que variam de 918,0 mm a 1.032,6 mm (Figura 7-B). É amplamente aceito que as recentes alterações climáticas alterem a precipitação anual, bem como a distribuição espacial (Banerjee *et al.*, 2020). A superfície da Terra passa por uma dinâmica de uso e ocupação do solo sem precedentes, por isso as séries temporais de análise por meio de imagens oriundas de satélites é de suma importância para acompanhar as tendências, detecção de padrões e, conseqüentemente, desenvolver modelos e prever as mudanças na superfície (Oliveira *et al.*, 2016). Esse tipo de análise deve ser estudado, principalmente, em nível de bacia hidrográfica, como é o caso

da ADBBP, a qual apresenta valores de precipitação média anual que variam de 792,7 mm a 941,7 mm, com média de 849 mm e $\sigma = \pm 30,7$ mm (Figura 7-C).

Os avanços recentes no processamento automatizado, a implementação de métodos e algoritmos avançados e o processamento baseado em nuvem permitiram um acesso muito mais amplo e rápido às imagens de satélite, e o GEE desempenhou papel vital nesse processo (Tamiminia *et al.*, 2020). Ao contrário das técnicas tradicionais, a qual a aquisição, o armazenamento de dados e o tempo de processamento possuem limitações significativas, particularmente para a análise de conjuntos de dados de séries temporais de grande magnitude (Mateo-García *et al.*, 2018), a plataforma GEE oferece uma vantagem significativa em comparação com o processamento tradicional SIG. Isso acontece porque o GEE utiliza imagens de satélites com mínimo esforço computacional em nível de hardwares, já que tais imagens não precisam ser baixadas (o acesso é sob demanda), armazenadas e processadas e acessadas diretamente em softwares instalados no computador (Peña-Monferrer; Manson-Sawko; Elisseev, 2021; Ghosh; Kumar; Kumari, 2022), conseqüentemente, há um ganho substancial na gestão de dados geoespaciais.

O GEE, também, oferece aplicações em diversas escalas espaciais e temporais que beneficiam o meio ambiente e a sociedade, permitindo processar de forma simples e rápida grandes quantidades de imagens de satélite em longos períodos, sem necessariamente possuir equipamentos computacionais de alto desempenho (Kumar; Mutanga, 2018). Isso viabiliza e propicia inúmeras oportunidades no ambiente científico, acadêmico e empresarial. Nos últimos anos, a análise de *big data* chamou a atenção em diferentes áreas, como negócios, ciências da saúde, ciências agrárias e geociências (Tamiminia *et al.*, 2020). Os referidos autores afirmam que o crescimento dos dados geoespaciais mudou a nossa percepção do planeta. Estas características levantaram vários desafios, incluindo a aquisição, armazenamento, pesquisa, compartilhamento, transferência, análise e visualização de *big data*.

Como há grandes desafios de processamento de dados geoespaciais obtidos, por meio de imagens de satélites e na geração de mapas de avaliação geoespacial para grandes áreas (> 10.000 km²) em diferentes escalas temporais (Ghosh; Kumar; Kumari, 2022), é relevante ressaltar que, em relação ao tempo de processamento computacional (*in cloud*), considerando uma velocidade média de internet para *download* de 98 Mbps e *upload* de 76 Mbps, utilizando-se de uma máquina do tipo laptop (Linux Mint 20.2 Cinnamon, CPU Intel (R) Core(TM) i7-4500U 4 núcleos, 1.80GHz, L2 cache 4096 KB, RAM 16 GB e SSD Kingston SA 400S3 e GPU 2.0 GB-GeForce GT 740M), para analisar a mesorregião do norte de Minas Gerais (128.368,265 km²), a rotina desenvolvida consumiu apenas 6", 9", 2'38", 3'35", respectivamente, para o primeiro, segundo, terceiro (período de 30 dias) e quarto módulo (período de 30 anos).

Alguns avanços e inovações destacaram-se neste trabalho: (i) apresenta uma validação espaço-temporal dos dados CHIRPS para mesorregião do norte de Minas, com série histórica superior a 30 anos; (ii) apresenta uma rotina 100% automatizada (Mendes *et al.*, 2023) e calibrada nos aspectos de extração e visualização (espaço-temporal) de dados pluviométricos; (iii) a rotina funciona em plataforma livre (e *open source*) e em nuvem, ou seja, no GEE, e pode ser obtida gratuitamente no seguinte endereço: (https://code.earthengine.google.com/?accept_repo=users/willerfoli/CHIRPS); (iv) a rotina apresenta excelente desempenho computacional; (v) apresenta flexibilidade para adaptação de análise em outras ROIs (bacias hidrográficas, municípios, macro e microrregião), bem como a continuidade de implementação de diferentes produtos, análises e índices pluviométricos para previsibilidade de eventos extremos de chuva; (vi) fornece ao usuário (pesquisadores, consultores e analista ambiental) uma nova ferramenta para análise espaço-temporal da precipitação pluviométrica, até então inexistente. Essas abordagens estão alinhadas com diversos trabalhos que tentam resolver os desafios com processamento, organização e análise de grandes volumes de dados (*big data*) de sensoriamento remoto, ou seja, realizar o processamento complexo dos fluxos de trabalho de conjuntos de dados de sensoriamento remoto e fornecer resultados rápidos, precisos e eficientes para diversas aplicações e em diferentes escalas (Tamiminia *et al.*, 2020; Ghosh; Kumar; Kumari, 2022).

Apesar dos avanços alcançados, vários caminhos podem ser seguidos para dar continuidade nessa pesquisa, visando comparar os dados CHIRPS com os dados terrestres (pluviômetros). O efeito da variabilidade espacial da altitude pode ser investigado, bem como o grau de correlação dos dados no período seco e chuvoso e, também, o grau de correlação para dados diários. Já em relação à rotina computacional, uma direção futura seria, a partir do código fonte disponível nesse trabalho, customizá-la de acordo com o(s) objetivo(s) pretendido(s) e disponibilizá-la no formato de *Earth Engine Apps*,

torando-a mais intuitiva e compartilhável. Outros módulos, também, poderão ser desenvolvidos, visando importar os dados de precipitação das estações meteorológicas e, conseqüentemente, realizar diferentes métodos de interpolação, tais como a Ponderação pelo Inverso da Distância (IDW), a *krigagem*, *Spline* de Tensão, a Malha Triangulada (TIN) ou Delaunay, entre outros.

CONSIDERAÇÕES FINAIS

Mesmo trabalhando com uma série histórica de 30 anos, observou-se uma amplitude maior dos valores de MAE e RMSE durante a estação chuvosa. Essa verificação pode ser explicada pela interferência de eventos como o ENOS que influencia na intensificação/redução de ZCAS, que ocorre apenas durante a primavera e verão (estação chuvosa na área estudada).

Entre os meses de outubro a março (meses com maior volume precipitado), as correlações foram maiores quando comparadas aos meses com menor precipitação. Destacaram-se os meses de janeiro e dezembro, maiores correlações entre os valores de precipitação preditos pelo modelo CHIRPS e os observados nas estações meteorológicas, com $r = 0,93$ e $r = 0,91$, respectivamente. Os meses de maio a setembro apresentaram correlações inferiores aos demais meses, sendo julho o mês com menor correlação.

Diante dos resultados encontrados nesse estudo e, também, da baixa densidade de estações meteorológicas terrestres na mesorregião do norte do Estado de Minas Gerais, recomenda-se a utilização do *dataset* CHIRPS como fonte alternativa de dados meteorológicos.

O trabalho apontou algumas vantagens em utilizar a plataforma GEE, quando comparado com os *softwares* tradicionais SIG. A plataforma utiliza *datasets* com mínimo esforço computacional em nível de *hardwares*, já que tais dados não precisam ser baixados, armazenados, processados e acessados diretamente em *softwares* instalados no computador. Também permite realizar análise espaço-temporal com grande volume de dados, em diferentes contextos geográficos (micro e mesorregiões, municípios, bacias hidrográficas etc.).

A rotina computacional desenvolvida apresenta grande potencial para analisar séries temporais de precipitação diária para regiões que não possuem dados pluviométricos, bem como para preencher lacunas desses dados. A rotina, também, é intuitiva, rápida e automatizada, pois não exige interferência do usuário para configuração de parâmetros, além de permitir a flexibilização para a continuidade de implementação de diferentes produtos, análises e índices pluviométricos para previsibilidade de eventos extremos de chuva.

AGRADECIMENTOS

À Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão de bolsas.

REFERÊNCIAS

- BABA, R. K.; VAZ, M. S. M. G.; COSTA, J. Correção de dados agrometeorológicos utilizando métodos estatísticos. **Revista Brasileira de Meteorologia**, v. 29, p. 515 - 526, 2014. <https://doi.org/10.1590/0102-778620130611>
- BAEZ-VILLANUEVA, O. M.; ZAMBRANO-BIGIARINI, M.; RIBBE, L.; NAUDITT, A.; GIRALDO-OSORIO, J. D.; THINH, N. X. Temporal and spatial evaluation of satellite rainfall estimates over different regions in Latin-America. **Atmospheric Research**, v. 213, p. 34-50, 2018. <https://doi.org/10.1016/j.atmosres.2018.05.011>
- BAI, L.; SHI, C.; LI, L.; YANG, Y.; WU, J. Accuracy of CHIRPS Satellite-Rainfall Products over Mainland China. **Remote Sensing**, v. 10, p. 362, 2018. <https://doi.org/10.3390/rs10030362>
- BANERJEE, A.; CHEN, R.; MEADOWS, M. E.; SINGH, R. B.; MAL, S.; SENGUPTA, D. An analysis of long-term rainfall trends and variability in the uttarakhand himalaya using google earth engine. **Remote Sensing**, v. 12, n. 4, p. 709, 2020. <https://doi.org/10.3390/rs12040709>

- CARNEIRO, M. de F. B. Região Norte de Minas: caracterização geográfica e a organização espacial - breves considerações. **Revista Cerrados**, Montes Claros, v. 1, n. 1, p. 91-105, 2003.
- COSTA, H. C.; MARCUZZO, F. F. N.; FERREIRA, O. M.; ANDRADE, L. R. Espacialização e Sazonalidade da Precipitação Pluviométrica do Estado de Goiás e Distrito Federal. **Revista Brasileira de Geografia Física**. Recife, v. 5, n. 1, p.87-100, 2012. <https://doi.org/10.26848/rbgf.v5i1.232785>
- COSTA, J. C.; PEREIRA, G.; SIQUEIRA, M. E.; CARDOZO, F.; SILVA, V. V. Validação dos dados de precipitação estimados pelo CHIRPS para o Brasil. **Revista Brasileira de Climatologia**, v. 24, 2019. <https://doi.org/10.5380/abclima.v24i0.60237>
- DE OLIVEIRA, S. S. T., CARDOSO, M. C., DOS SANTOS, W. M. V., COSTA, P. C. P., RODRIGUES, V. J. S., MARTINS, W. S. A new platform for time-series analysis of remote sensing images in a distributed computing environment. In: **GeoInfo**, Campos do Jordão, p. 128-139, 2016.
- DOS SANTOS, B. C., SANCHES, R.G., DE MELO BOLLELI, T., DE SOUZA, P.H., BOURSCHIEDT, V. On the quality of satellite-based precipitation estimates for time series analysis at the central region of the state of São Paulo, Brazil. **Theoretical and Applied Climatology**, v. 151, p. 467-489, 2023. <https://doi.org/10.1007/s00704-022-04287-y>
- DUBEY, S.; GUPTA, H.; GOYAL, M. K.; JOSHI, N. Evaluation of precipitation datasets available on Google earth engine over India. **International Journal of Climatology**, v. 41, n. 10, p. 4844-4863, 2021. <https://doi.org/10.1002/joc.7102>
- ESPINOZA, J.; MARENGO, J. A.; SCHONGART, J.; JIMENEZ, J. C. The new historical flood of 2021 in the Amazon river compared to major floods of the 21st century: atmospheric features in the context of the intensification of floods. **Weather and Climate Extremes**, v. 35, p. 1-12, 2022. <https://doi.org/10.1016/j.wace.2021.100406>
- FISCH, G., MARENGO, J. A., NOBRE, C. A. Uma revisão geral do clima da Amazônia. **Acta amazônica**, v. 28, p. 101-126, 1998. <https://doi.org/10.1590/1809-43921998282126>
- FREITAS, L. O.; CALHEIROS, T.; DOS REIS, R. J. Vulnerabilidade da mesorregião Norte de Minas Gerais face às mudanças climáticas. **Caderno de Geografia**, v. 29, n. 56, 2019. <https://doi.org/10.5752/P.2318-2962.2019v29n56p134>
- FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; SHUKLA, S.; HUSAK, G.; ROWLAND, J.; HARRISON, L.; HOELL, A.; MICHAELSEN, J. The climate hazards infrared precipitation with stations-a new environmental record for monitoring extremes. **Scientific Data**, p. 150066, 2015. <https://doi.org/10.1038/sdata.2015.66>
- GHOSH, S.; KUMAR, D.; KUMARI, R. Cloud-based large-scale data retrieval, mapping, and analysis for land monitoring applications with google earth engine (GEE). **Environmental Challenges**, v. 9, p. 100605, 2022. <https://doi.org/10.1016/j.envc.2022.100605>
- GOMES, D. J. C.; BELTRÃO, N. E. S.; PEREIRA, F. M.; REIS, A. C. M.; PINHEIRO, A. M. P.; DA SILVA, D. F. Estimativa de precipitação dos dados CHIRPS e GPCC em anos de extremos climáticos, Bacia Hidrográfica do rio Guamá-PA. **Revista Brasileira de Geografia Física**, v.15, n. 3, p. 1583-1598, 2022. <https://doi.org/10.26848/rbgf.v15.3.p1583-1598>
- GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote sensing of Environment**, v. 202, p. 18-27, 2017. <https://doi.org/10.1016/j.rse.2017.06.031>
- GRIMM, A. M.; SANT'ANNA, C. L. S. Influência de Fases Extremas da Oscilação Sul sobre a Intensidade e Frequência da Chuvas no Sul do Brasil. In: **Congresso Brasileiro de Meteorologia**. Rio de Janeiro, 2000.
- HINRICHS, S.; MARIANETTI, G.; RIVERA, J.; MULENA, C.; GRECO, F. Uso de las estimaciones chirps como complemento de las observaciones de precipitación en la cuenca del río Mendoza. **Revista Jornadas de Investigación**, 2019.
- HU, Q.; LI, Z.; WANG, L.; HUANG, Y.; WANG, Y.; LI, L. Rainfall spatial estimations: A review from spatial interpolation to multi-source data merging. **Water**, v. 11, n. 3, p. 579, 2019. <https://doi.org/10.3390/w11030579>

- IBGE - Instituto Brasileiro de Geografia e Estatística. **Malha Municipal**. 2021. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/malhas-territoriais/15774-malhas.html?=&t=sobre>. Acesso em: 17 out. 2023.
- INMET- Instituto Nacional de Meteorologia. **Mapa de Estações**. 2023. Disponível em: <https://mapas.inmet.gov.br/>. Acesso em: 17 out. 2023.
- KIDD, C.; SHIGE, S.; VILA, D.; TARNAVSKY, E.; YAMAMOTO, M. K.; MAGGIONI, V.; MASEKO, B. The IPWG Satellite Precipitation Validation Effort. **Springer**, p. 453-470, 2020. <https://doi.org/10.1007/978-3-030-35798-6>
- KUMAR, L.; MUTANGA, O. Google Earth Engine applications since inception: Usage, trends, and potential. **Remote sensing**, v. 10, n. 10, p. 1509, 2018. <https://doi.org/10.3390/rs10101509>
- LÓPEZ-BERMEJO, C., MONTOYA, R. D., CARO-LOPERA, F. J., DIAZ-GRACIA, J. A. Validation of the accuracy of the CHIRPS precipitation dataset at representing climate variability in a tropical mountainous region of South America. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 127, p. 103184, 2022. <https://doi.org/10.1016/j.pce.2022.103184>
- MATEO-GARCÍA, G.; GÓMEZ-CHOVA, L.; AMORÓS-LÓPEZ, J.; MUÑOZ-MARI, J.; CAMPS-VALLS, G. Multitemporal cloud masking in the Google Earth Engine. **Remote Sensing**, v. 10, n. 7, p. 1079, 2018. <https://doi.org/10.3390/rs10071079>
- MELO, V. S.; LIMA, L. M. Caracterização da chuva da microrregião de Catolé do Rocha no Estado da Paraíba em estatística aplicada. **Revista Brasileira de Meteorologia**, v. 36, n. (1, p. 97-106, 2021. <https://doi.org/10.1590/0102-77863610006>
- MENDES, L.P.O.; ROMEIRO, M.R.M.; PIMENTA, L.J.L.; DE OLIVEIRA, W.F.; DOS SANTOS, S.R. PluvCHIRPS-V1 [Video]. **GeoRaster - RST**. YouTube. Disponível em: <https://youtu.be/XOjAV9MGKs4>. Acesso em: 04 de jan. 2024.
- MOLLA, A.; DI, L.; GUO, L.; ZHANG, C.; CHEN, F. Spatio-Temporal Responses of Precipitation to Urbanization with Google Earth Engine: A Case Study for Lagos, Nigeria. **Urban Science**, v. 6, n. 2, p. 40, 2022. <https://doi.org/10.3390/urbansci6020040>
- PACA, V. H. M.; ESPINOZA-DÁVALOS, G. E.; MOREIRA, D. M.; COMAIR, G. Variability of Trends in Precipitation across the Amazon River Basin Determined from the CHIRPS Precipitation Product and from Station Records. **Water**, v. 12, p. 1244, 2020. <https://doi.org/10.3390/w12051244>
- PALHARINI, R. S. A.; VILA, D. A.; RODRIGUES, D. T.; PALHARINI, R. C.; MATTOS, E. V.; PEDRA, G. U. Assessment of extreme rainfall estimates from satellite-based: Regional analysis. **Remote Sensing Applications: Society and Environment**, v. 23, p. 100603, 2021. <https://doi.org/10.1016/j.rsase.2021.100603>
- PEÑA-MONFERRER, C.; MANSON-SAWKO, R.; ELISSEEV, V. HPC-cloud native framework for concurrent simulation, analysis and visualization of CFD workflows. **Future Generation Computer Systems**, v. 123, p. 14-23, 2021. <https://doi.org/10.1016/j.future.2021.04.008>
- REBOITA, M. S.; OLIVEIRA, K. R.; CORRÊA, P. Y. C.; RODRIGUES, R. Influência dos diferentes tipos do fenômeno El Niño na precipitação da América do Sul. **Revista Brasileira de Geografia Física**, v. 14, n. 2, p. 729-742, 2021. <https://doi.org/10.26848/rbgf.v14.2.p729-742>
- RINCÓN-AVALOS, P.; KHOUAKHI, A.; MENDOZA-CANO, O.; LA CRUZ, J. L.; PAREDES-BONILLA, K. M. Evaluation of satellite precipitation products over Mexico using Google Earth Engine. **Journal of Hydroinformatics**, v. 24, n. 4, p. 711-729, 2022. <https://doi.org/10.2166/hydro.2022.122>
- RIVERA, J. A.; MARIANETTI, G.; HINRICHS, S. Validation of CHIRPS precipitation dataset along the Central Andes of Argentina. **Atmospheric Research**, v. 213, n. 15, p. 437-449, 2018. <https://doi.org/10.1016/j.atmosres.2018.06.023>
- ROCHA, N. C. V.; LIMA, A. M. M. Water sustainability of the Guamá river basin, Eastern Amazonia/Brazil. **Sociedade & Natureza**, v. 32, p. 130-148, 2020. <https://doi.org/10.14393/SN-v32-2020-45694>

RUEZZENE, C. B.; MIRANDA, R. B.; TECH, A. R. B.; MAUAD, F. F. Preenchimento de falhas em dados de precipitação através de métodos tradicionais e por inteligência artificial. **Revista Brasileira de Climatologia**, v. 29, p. 177-204, 2021.

SANTOS, B. C.; SANCHES, R. G.; BOLLELI, T. M.; SOUZA, P. H.; BOURSCHEIDT, V. On the quality of satellite-based precipitation estimates for time series analysis at the central region of the state of São Paulo, Brazil. **Theoretical and Applied Climatology**, v. 151, n. 1-2, p. 467-489, 2023. <https://doi.org/10.1590/s1413-41522016146750>

SHEEL, I.; HINNERICHSEN, M. The Impact of Climate Change on Precipitation-related Insurance Risk: A Study of the Effect of Future Scenarios on Residential Buildings in Norway. **The Geneva Papers**. Risk Insur. Issues Pract., v. 37, p. 365-376, 2012. <https://doi.org/10.1057/gpp.2012.7>

SHRESTHA, N. K.; QAMER, F. M.; PEDREROS, D.; MURTHY, M. S. R.; WAHID, S. M.; SHRESTHA, M. Evaluating the accuracy of Climate Hazard Group (CHG) satellite rainfall estimates for precipitation based drought monitoring in Koshi basin, Nepal. **Journal of Hydrology: Regional Studies**, v. 13, p. 138-151, 2017. <https://doi.org/10.1016/j.ejrh.2017.08.004>

SILVA, C. B.; SILVA, M. E. S.; AMBRIZZI, T.; TOMMASELLI, J. T. G.; PATUCCI, N. N.; MATAVELI, G. A. V.; LIMA, B. S.; CORREA, W. C. Precipitação na América do Sul – dados obtidos em estações meteorológicas automáticas e sistemas orbitais. **Revista Brasileira de Climatologia**, v. 25, p. 54-79, 2019. <https://doi.org/10.1016/j.ejrh.2017.08.004>

SILVA; E. R. M., BARBOSA; I. C. C., SILVA; H. J. F., COSTA; L. G. S., ROCHA, E. J. P. Análise do Desempenho da Estimativa de Precipitação do Produto CHIRPS para Sub-Bacia do Rio Apeú, Castanhal-PA. **Revista Brasileira de Geografia Física**, v. 13, n. 03, p. 1094-1105, 2020. <https://doi.org/10.26848/rbqf.v13.3.p1094-1105>

SILVA NETO, V. L.; VIOLA, M. R.; MELLO, C. R.; ALVES, M. V. G.; SILVA, D. D.; PEREIRA, S. B. Mapeamento de chuvas intensas para o Estado do Tocantins. **Revista Brasileira de Meteorologia**, v. 35, n. 1, p. 1-11, 2020. <https://doi.org/10.1590/0102-7786351017>

TAMIMINIA, H.; SALEHI, B.; MAHDIANPARI, M.; QUACKENBUSH, L.; ADELI, S.; BRISCO, B. Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 164, p. 152-170, 2020. <https://doi.org/10.1016/j.isprsjprs.2020.04.001>

TOTÉ, C.; PATRICIO, D.; BOOGAARD, H.; VAN DER WIJNGAART, R.; TARNAVSKY, E.; Funk, C. Evaluation of Satellite Rainfall Estimates for Drought and Flood Monitoring in Mozambique. **Remote Sens**, v. 7, p. 1758-1776, 2015. <https://doi.org/10.3390/rs70201758>

USGS-United States Geological Survey. **Earth Resources Observation and Science (EROS) Center**. USGS EROS Archive -Digital Elevation-Shuttle Radar Topography Mission (SRTM) Non-Void Filled. 2018. Disponível em: https://www.usgs.gov/centers/eros/science/usgs-eros-archive-digital-elevation-shuttle-radar-topography-mission-srtm-non?qt-science_center_objects=0#qt-science_center_objects. Acesso em: 14 set. 2023.

VÁSQUEZ, P. L. M. N.; MOLION, L. C. B.; ARAUJO ABDALAD, M.; MOREIRA, D. M.; SANCHEZ, A. Historical analysis of interannual rainfall variability and trends in southeastern Brazil based on observational and remotely sensed data. **CLIMATE DYNAMICS**, v. 50, n. 3, p. 801-824, 2018. <https://doi.org/10.1007/s00382-017-3642-9>

ZHAO, F.; FENG, S.; XIE, F.; ZHU, S.; ZHANG, S. Extraction of long time series wetland information based on Google Earth Engine and random forest algorithm for a plateau lake basin-A case study of Dianchi Lake, Yunnan Province, China. **Ecological Indicators**, v. 146, p. 109813, 2023. <https://doi.org/10.1016/j.ecolind.2022.109813>

Recebido em: 04/03/2024

Aceito para publicação em: 25/04/2024