



**VALIDAÇÃO E ANÁLISE ESPAÇO-TEMPORAL DE DADOS DE
PRECIPITAÇÃO OBTIDOS POR SENSORIAMENTO REMOTO
CHIRPS PARA O ESTADO DE MATO GROSSO, BRASIL**

*Validation and Spatio-Temporal Analysis of Precipitation Data
Obtained by CHIRPS Remote Sensing for the State of Mato
Grosso, Brazil*

*Validación y Análisis Espacio-Temporal de Datos de
Precipitación Obtenidos por Sensores Remotos CHIRPS para el
Estado de Mato Grosso, Brasil*

Eduardo Morgan Uliana  

Universidade Federal de Mato Grosso - UFMT
eduardo.uliana@ufmt.br

Marionei Fomaca de Sousa Junior  

Instituto Nacional de Pesquisas Espaciais - INPE
mariofomacajr@gmail.com

Juliana de Abreu Araujo  

Instituto Nacional de Pesquisas Espaciais - INPE
j.abreuaraujo28@gmail.com

Uilson Ricardo Venâncio Aires  

Mississippi State University
uilson.aires@msstate.edu

Demetrius David da Silva  

Universidade Federal de Viçosa - UFV
demetrius@ufv.br

Marcio Roggia Zanuzo  

Universidade Federal de Mato Grosso - UFMT
marcio.zanuzo@ufmt.br

Ibraim Fantin da Cruz  

Universidade Federal de Mato Grosso - UFMT
ibraimfantin@gmail.com

Resumo: A precipitação é crucial para a produção agrícola no estado do Mato Grosso. Contudo, a rede de monitoramento dos dados de chuvas é insuficiente e desuniformemente distribuída, afetando a determinação do balanço hídrico, a detecção de secas e a gestão de recursos hídricos. Considerando o potencial dos produtos de precipitação oriundos de sensoriamento remoto para estimar a precipitação em locais com monitoramento deficiente, este trabalho teve como objetivo validar os dados CHIRPS (Climate Hazards Group InfraRed Precipitation with Station data) para o estado de Mato Grosso, bem como analisar sua distribuição espacial e temporal na região. As estimativas do CHIRPS foram comparadas com séries históricas registradas em 154 estações pluviométricas da rede hidrometeorológica nacional, tendo sido quantificadas seis métricas de erro para validação do produto. A partir dos resultados obtidos confirmou-se que o bioma Amazônia apresenta a maior precipitação do estado, seguido pelo Cerrado. Em contraste, o bioma Pantanal possui a menor precipitação média mensal e anual em comparação aos outros biomas do estado. Comprovou-se, ainda, que o produto CHIRPS estima de forma adequada a precipitação total mensal e a média histórica mensal, revelando-se uma ferramenta promissora para a gestão de recursos hídricos, detecção de secas, estudos de balanço hídrico e modelagem hidrológica em bacias hidrográficas no estado de Mato Grosso. Contudo, para totais diários, o erro de estimativa é elevado, não sendo recomendada sua utilização direta sem correção dos dados ou calibração em modelos hidrológicos.

Palavras-chave: Pluviometria. Agricultura. CHIRPS. Biomas. Monitoramento.

Abstract: Precipitation is essential for agricultural production in the state of Mato Grosso. However, the rain gauge monitoring network is insufficient and unevenly distributed, which impacts the determination of water balance, drought detection, and water resource management. Given the potential of remote sensing-derived precipitation products for estimating rainfall in sparsely monitored areas, this study aimed to validate the CHIRPS (Climate Hazards Group InfraRed Precipitation with Station data) product for the state of Mato Grosso, as well as to analyze its spatial and temporal distribution across the region. CHIRPS estimates were compared with historical records from 154 rain gauges in the national hydrometeorological network, and six error metrics were quantified to validate the product. Results confirmed that the Amazon biome receives the highest precipitation in the state, followed by the Cerrado, while the Pantanal biome records the lowest average monthly and annual precipitation among the state's biomes. Additionally, CHIRPS was found to adequately estimate total monthly precipitation and historical monthly averages, positioning it as a promising tool for water resource management, drought detection, water balance studies, and hydrological modeling in Mato Grosso's watersheds. However, due to high estimation errors in daily totals, direct use without data correction or calibration in hydrological models is not recommended.

Keywords: Rainfall. Agriculture. CHIRPS. Biomes. Monitoring.

Resumen: La precipitación es crucial para la producción agrícola en el estado de Mato Grosso. Sin embargo, la red de monitoreo de datos de lluvia es insuficiente y está desigualmente distribuida, lo que afecta la determinación del balance hídrico, la detección de sequías y la gestión de recursos hídricos. Considerando el potencial de los productos de precipitación derivados del monitoreo remoto para estimar la precipitación en áreas con monitoreo deficiente, este estudio tuvo como objetivo validar los datos CHIRPS (Climate Hazards Group InfraRed Precipitation with Station data) para el estado de Mato Grosso, así como analizar su distribución espacial y temporal en la región. Las estimaciones de CHIRPS fueron comparadas con registros históricos de 154 pluviómetros de la red hidrometeorológica nacional, y se cuantificaron seis métricas de error para validar el producto. Los resultados confirmaron que el bioma Amazónico presenta la mayor precipitación en el estado, seguido por el Cerrado. En contraste, el bioma Pantanal tiene la menor precipitación media mensual y anual en comparación con los otros biomas del estado. Además, se comprobó que el producto CHIRPS estima

adecuadamente la precipitación total mensual y los promedios históricos mensuales, revelándose como una herramienta prometedora para la gestión de recursos hídricos, la detección de sequías, estudios de balance hídrico y modelado hidrológico en cuencas hidrográficas en el estado de Mato Grosso. Sin embargo, para totales diarios, el error de estimación es alto, no recomendándose su uso directo sin corrección de datos o calibración en modelos hidrológicos.

Palabras clave: Pluviometría. Agricultura. CHIRPS. Biomás. Monitoreo.

Submetido em: 14/08/2024

Aceito para publicação em: 08/11/2024

Publicado em: 20/11/2024

1. INTRODUÇÃO

A precipitação é a principal fonte de entrada de água em uma bacia hidrográfica e desempenha um papel crucial na dinâmica do ciclo hidrológico. Este componente hidrológico tem influência expressiva na disponibilidade hídrica das bacias, recarga dos aquíferos e geração de escoamento superficial, afetando diretamente diversas atividades econômicas urbanas, a geração de energia, os sistemas de transporte, bem como as práticas de manejo e produção agrícola.

A precipitação, ao influenciar a quantidade de água disponível, condiciona a recarga subterrânea, o escoamento superficial e a evapotranspiração em bacias hidrográficas, sendo, portanto, um fator determinante no planejamento e gestão de recursos hídricos.

A precipitação em uma localidade pode ser medida pontualmente com equipamentos como pluviômetros ou pluviógrafos. Além dos métodos diretos, existem também formas indiretas de determinação da precipitação, como radares meteorológicos e produtos derivados do sensoriamento remoto orbital, que permitem uma avaliação mais rápida da distribuição espacial da chuva em uma região (Mello; Silva; Beskow, 2020).

Apesar de a medição direta da precipitação ser relativamente simples e utilizar equipamentos de baixo custo, as redes de monitoramento em países em desenvolvimento ainda apresentam baixa densidade e pequena extensão das séries históricas. No Cerrado, Junqueira et al. (2022) afirmam que densidade da rede hidrometeorológica é muito abaixo da recomendada pela Organização Mundial de Meteorologia (WMO). Segundo Alejo e Alejandro (2021), a escassez de dados de precipitação e a baixa densidade das redes meteorológicas prejudicam o planejamento de recursos hídricos em muitos países em desenvolvimento.

A área de estudo deste trabalho foi o Estado de Mato Grosso, localizado na região Centro-Oeste do Brasil. O Estado destaca-se pela produção agrícola e pecuária, sendo a soja, o milho, o algodão e o feijão as principais culturas comerciais. Nos últimos anos, o número de empreendimentos de irrigação por pivô central aumentou nas bacias hidrográficas de Mato Grosso e continua crescendo devido ao alto potencial da região para a produção de grãos (ANA, 2020). O estado está inserido em três biomas brasileiros: Pantanal, Cerrado e Amazônia, e abriga três importantes cabeceiras de rios no contexto nacional: Tocantins-Araguaia, Amazonas (alto rio Tapajós e rio Xingu) e Paraguai.

O fato da maior parte da produção agrícola no estado de Mato Grosso ocorrer em sistema de sequeiro destaca ainda mais a insuficiência da rede de monitoramento da precipitação. Essa deficiência compromete a gestão eficiente dos recursos hídricos, a análise climática, a implementação de estratégias de manejo de irrigação e o monitoramento de secas. Muitas bacias hidrográficas possuem uma quantidade limitada de informações sobre a precipitação, o que dificulta a realização de estudos de balanço hídrico. Parte da baixa densidade de estações deve-se à dificuldade de acesso a certas localidades ou a problemas operacionais para o funcionamento dos equipamentos em áreas de vegetação densa, como unidades de conservação, terras indígenas e áreas sujeitas a alagamentos naturais nos biomas de Mato Grosso.

Uma solução para contornar o problema mencionado é adquirir informações de precipitação para estudos hidrológicos nessas áreas com monitoramento deficiente através de produtos de chuva estimados por sensoriamento remoto. Entre esses produtos, destaca-se o Climate Hazards Group Infrared Precipitation with Stations (CHIRPS), que combina dados de sensores infravermelho de satélites com medições de precipitação em estações de superfície. Entretanto, de acordo com autores como Saragih et al. (2022) e Maggioni e Massari (2018), a utilização de dados de sensoriamento remoto para a tomada de decisões requer validação local em decorrência das variações regionais e sazonais nos erros desses produtos, sendo necessário compará-los com dados de superfície para garantir sua precisão e acurácia.

Nesse contexto, estudos como os de Dinku et al. (2018), Aksu e Akgül (2020), Alejo e Alejandro (2021), Alsilibe et al. (2023), Ghozat, Sharafati e Hosseini (2022), Katsanos, Retalis e Michaelides (2016), Nawaz; Iqbal; Mahmood (2021), e Paredes-Trejo; Barbosa; Kumar (2017) realizaram essa validação em países da África Oriental, Turquia, Filipinas, Síria, Irã, Chipre, Paquistão e nordeste do Brasil, respectivamente. Esses estudos constataram que o produto CHIRPS apresenta desempenho adequado e potencial para estimar e analisar a distribuição espacial e temporal da precipitação em áreas com monitoramento deficiente.

Diante do exposto, e considerando o potencial de utilização de produtos oriundos de sensoriamento remoto para a estimativa de precipitação, o objetivo deste trabalho foi validar os dados CHIRPS para o estado de Mato Grosso, bem como analisar sua distribuição espacial e temporal na região.

2. METODOLOGIA

2.1 Área de Estudo

A área de estudo deste trabalho foi o Estado de Mato Grosso, situado na região Centro-Oeste do Brasil, conhecido por sua destacada produção agrícola de soja, milho, feijão e algodão. De acordo com o Censo Agropecuário de 2017 (IBGE, 2017) a produção dessas culturas foi estimada em 29.778,5 mil toneladas de soja, 28.555,9 mil toneladas de milho, 305,2 mil toneladas de feijão e 2.397,9 mil toneladas de algodão. As áreas de plantio correspondentes para cada cultura foram, aproximadamente, de 8.862,7 mil hectares para soja, 4.829,7 mil hectares para milho, 207,0 mil hectares para feijão e 596,6 mil hectares para algodão.

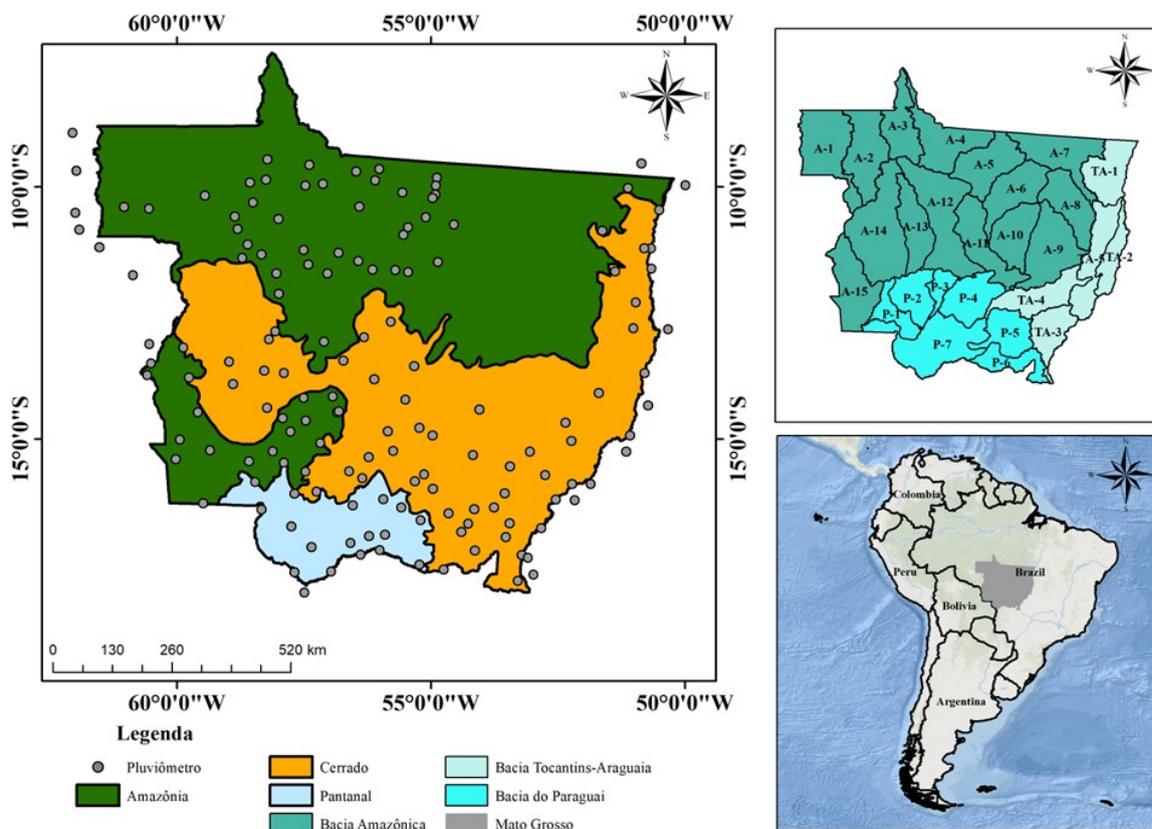
Além de sua destacada produção agrícola, a área irrigada do estado está crescendo, especialmente através de empreendimentos com pivôs centrais, conforme indicado pela ANA (2020). Mato Grosso também possui diversas usinas hidrelétricas em seus rios, sendo as maiores as UHEs Manso, Sinop, Colíder, Teles Pires e São Manuel.

Na Figura 1 apresenta-se o mapa do estado de Mato Grosso, destacando a localização das estações pluviométricas, biomas e Unidades de Planejamento e Gestão de Recursos Hídricos (UPGs), que estão descritas na Tabela 1.

2.2 Base de dados

Para realização da pesquisa foram utilizadas séries históricas de 154 estações pluviométricas da rede hidrometeorológica nacional, pertencente à Agência Nacional de Águas e Saneamento Básico (ANA), cujas informações estão apresentadas na Tabela 2.

Figura 1 - Mapa da área de estudo com destaque para a localização da rede de monitoramento pluviométrico, biomas e unidades de planejamento e gestão de recursos hídricos do estado do Mato Grosso.



Fonte: Elaborado pelos autores (2024).

Tabela 1 - Detalhes das unidades de planejamento e gestão de recursos hídricos (UPGs) do estado de Mato Grosso.

Código	Nome	Código	Nome
A-1	Roosevelt	A-15	Guaporé
A-2	Aripuanã	TA-1	Baixo Araguaia
A-3	Baixo Juruena	TA-2	Médio Araguaia
A-4	Baixo Teles Pires	TA-3	Alto Araguaia
A-5	Médio Teles Pires	TA-4	Alto Rio das Mortes
A-6	Manissauá-Miçú	TA-5	Baixo Rio das Mortes
A-7	Médio Xingu	P-1	Jaurú
A-8	Suiá-Miçú	P-2	Alto Paraguai Médio
A-9	Alto Xingu	P-3	Alto Paraguai Superior
A-10	Ronuro	P-4	Alto Rio Cuiabá
A-11	Alto Teles Pires	P-5	São Lourenço
A-12	Arinos	P-6	Correntes – Taguarí
A-13	Sangue	P-7	Paraguai - Pantanal
A-14	Alto Juruena		

Fonte: Elaborado pelos autores (2024).

Tabela 2 - Informações das estações pluviométricas da rede hidrometeorológica nacional utilizados no estudo

Código	Latitude	Longitude	Município	Período	Código	Latitude	Longitude	Município	Período
00862000	-8,9322	-62,0556	Machadinho D'oeste	1981-2022	01450000	-14,3328	-50,7303	Nova Crixás	1981-2022
00950002	-9,9703	-49,9936	Pium	1984-2022	01451000	-14,9275	-51,0828	Aruanã	1981-2022
00950003	-9,5353	-50,8608	Santana do Araguaia	2000-2021	01452000	-14,6722	-52,3547	Nova Xavantina	1981-2022
00951000	-10,0189	-51,1228	Vila Rica	1984-2022	01454000	-14,4178	-54,0494	Paranatinga	1981-2022
00954001	-9,8186	-54,8864	Guarantã do Norte	1984-2022	01454002	-14,9261	-54,9728	Nova Brasilândia	1983-2022
00954002	-9,9756	-54,9042	Guarantã do Norte	2005-2022	01455008	-14,8439	-55,8550	Rosário Oeste	1981-2022
00956000	-9,8703	-56,1022	Alta Floresta	1981-2022	01455009	-14,2206	-55,5067	Nobres	2000-2022
00956001	-9,6433	-56,0186	Alta Floresta	1981-2022	01455010	-14,7772	-55,2333	Nova Brasilândia	2000-2022
00956002	-9,6939	-56,4742	Paranaita	2000-2022	01456001	-14,4694	-56,8500	Arenópolis	1981-2022
00957001	-9,5664	-57,3947	Apiacás	1984-2022	01456003	-14,4511	-56,8142	Nortelândia	1981-2022
00957002	-9,9769	-57,4739	Nova Monte Verde	2000-2022	01456009	-14,1564	-56,9331	Diamantino	1981-2022
00958002	-9,4561	-58,2242	Cotriguaçu	2000-2022	01457000	-14,8506	-57,7678	Tangará da Serra	1981-2022
00958004	-9,9133	-58,5642	Cotriguaçu	2004-2022	01457001	-14,6322	-57,4686	Barra do Bugres	1981-2022
00961003	-9,6814	-61,9789	Machadinho D'oeste	1987-2022	01457003	-14,1833	-57,5069	Diamantino	1982-2022
01050000	-11,2192	-50,6686	Luciara	1984-2022	01457004	-14,5847	-57,9250	Tangará da Serra	2000-2022
01050002	-10,4611	-50,5125	Fortaleza do Tabocão	1985-2022	01458002	-14,3842	-58,2344	Tangará da Serra	1982-2022
01051001	-10,8672	-51,6306	Porto Alegre do Norte	1984-2022	01459003	-14,4694	-59,5939	Nova Lacerda	2000-2022
01054000	-10,7461	-54,5461	Marcelândia	1981-2022	01551000	-15,2461	-51,1633	Britânia	1981-2022
01054002	-10,1503	-54,9189	Matupá	2005-2022	01551002	-15,8900	-51,8536	Aragarças	1981-2022
01055000	-10,2203	-54,9711	Peixoto de Azevedo	2003-2022	01552000	-15,8914	-52,2278	Aragarças	1981-1998
01055001	-10,1125	-55,5700	Carlinda	1981-2022	01552001	-15,7111	-52,7544	General Carneiro	1981-2022
01055002	-10,7986	-55,4486	Colíder	1982-2022	01552002	-15,2503	-53,0553	Barra do Garças	1981-2022
01055003	-10,9542	-55,5486	Colíder	1994-2019	01552006	-15,0356	-52,2375	Barra do Garças	1983-2022
01055004	-10,6044	-55,1033	Terra Nova do Norte	2000-2022	01553003	-15,5419	-53,4519	General Carneiro	2000-2021
01056001	-10,3894	-56,4172	Alta Floresta	2000-2022	01554005	-15,3147	-54,1758	Primavera do Leste	1981-2022
01057001	-9,9417	-57,1331	Nova Monte Verde	1982-2022	01554006	-15,9889	-54,9683	Jaciara	1981-2022
01058002	-9,8564	-58,2489	Cotriguaçu	1982-2022	01555005	-15,8361	-55,3219	Campo Verde	1981-2022
01058003	-10,3125	-58,5017	Juruena	1984-2022	01555008	-15,2328	-55,7411	Chapada dos Guimarães	1982-2022
01058004	-10,8342	-58,8033	Castanheira	1984-2022	01560000	-15,3550	-56,2317	Cuiabá	1981-2022
01058005	-10,5886	-58,8678	Aripuanã	1985-2022	01560001	-15,7739	-56,3497	Nossa Senhora do Livramento	1981-2022
01058006	-10,6397	-58,0039	Juara	2000-2021	01560006	-15,6353	-56,6117	Várzea Grande	1981-2022
01059000	-10,1753	-59,4517	Aripuanã	1981-2022	01560007	-15,6986	-55,1356	Várzea Grande	1981-2022
01060001	-10,4344	-60,5572	Aripuanã	2000-2022	01557001	-15,0767	-57,1825	Barra do Bugres	1981-2021
01061001	-10,8494	-61,9306	Jiparaná	1981-1997	01557003	-15,6422	-57,4750	Porto Estrela	1981-2022
01061002	-10,3969	-61,0453	Rondolândia	1982-2022	01558000	-15,2453	-58,1133	Rio Branco	1983-2022
01061003	-10,5169	-62,0014	Ouro Preto do Oeste	1987-2022	01558001	-15,4692	-57,8942	Mirassol D'oeste	1981-2022
01150001	-11,6197	-50,6625	São Félix do Araguaia	1981-2022	01558004	-15,4400	-58,5878	Indiavaí	1981-2022
01150006	-11,2203	-50,8072	Luciara	2000-2022	01558005	-15,8533	-58,4658	Porto Esperidião	1981-2022
01151000	-11,6747	-51,3764	Alto Boa Vista	1984-2022	01559000	-15,2242	-59,3503	Pontes e Lacerda	1981-2022
01154004	-11,4933	-54,8656	Cláudia	2004-2022	01559006	-15,0081	-59,9492	Vila Bela da Santíssima Trindade	1981-2022
01155000	-11,6511	-55,7025	Sinop	1981-2022	01560000	-15,4003	-60,0317	Vila Bela da Santíssima Trindade	1981-2022
01156000	-11,4714	-56,4333	Tabaporã	1982-2022	01652000	-16,2092	-52,1686	Bom Jardim de Goiás	1981-2022
01156001	-11,6914	-55,4486	Porto dos Gaúchos	1983-2022	01652001	-16,7664	-52,8372	Ponte Branca	1981-2022
01156002	-11,3047	-56,8250	Tabaporã	2004-2022	01652002	-16,2014	-52,5500	Torixóreu	1981-2022
01156003	-11,6447	-56,1572	Porto dos Gaúchos	2004-2022	01653000	-16,0767	-53,5511	Tesouro	1981-2022
01157000	-11,5358	-57,4172	Porto dos Gaúchos	1981-2022	01653002	-16,3528	-53,7608	Guiratinga	1981-2022
01157001	-11,2531	-57,5067	Juara	1983-2022	01653004	-16,9442	-53,5336	Alto Garças	1981-2022
01157002	-11,7150	-57,0419	Porto dos Gaúchos	2000-2022	01653005	-16,6689	-53,4536	Araguaína	1983-2022
01158001	-11,3417	-58,3383	Juína	1981-2021	01654000	-16,4711	-54,6561	Rondonópolis	1981-2022
01158002	-11,4081	-58,7186	Juína	1984-2022	01654001	-16,6739	-54,2661	Pedra Preta	1981-2022
01158003	-11,7178	-58,0472	Brasnorte	1984-2022	01654004	-16,8431	-54,4081	Pedra Preta	1981-2022
01158004	-11,1400	-58,6161	Castanheira	2004-2022	01654005	-16,3911	-54,1494	Guiratinga	1984-2022
01160002	-11,7489	-60,8678	Pimenta Bueno	1983-2022	01655000	-16,3561	-55,5864	Barão de Melgaço	1981-2022
01161003	-11,1969	-61,5281	Ministro Andreazza	2000-2022	01655001	-16,6081	-55,2064	Santo Antônio do Leverger	1981-2022
01250000	-12,8206	-50,3361	São Miguel do Araguaia	1981-2022	01655002	-16,1936	-55,9453	Barão de Melgaço	1981-2022
01250001	-12,2903	-50,9656	Novo Santo Antônio	1981-2022	01655004	-16,8939	-55,9072	Barão de Melgaço	1981-2022
01251002	-12,8050	-51,0194	Ribeirão Cascalheira	2000-2022	01656002	-16,3147	-56,5436	Pocóné	1981-2022
01255001	-12,6750	-55,7931	Sorriso	1984-2021	01656003	-16,9211	-56,2236	Barão de Melgaço	1981-2022
01256002	-12,9806	-56,3156	Lucas do Rio Verde	2000-2021	01657002	-16,7336	-57,7503	Cáceres	1981-2022
01257000	-12,1164	-58,0003	Brasnorte	1984-2022	01657003	-16,0817	-57,6942	Cáceres	1981-2022
01258001	-12,8675	-58,0703	Brasnorte	2000-2022	01657004	-16,0392	-57,2575	Cáceres	1981-2022
01350000	-13,6894	-50,7961	Nova Crixás	1981-2022	01658000	-16,3944	-58,3389	Cáceres	1981-2022
01351000	-14,0881	-51,6989	Cocalinho	1984-2022	01659001	-16,2708	-59,4919	Vila Bela da Santíssima Trindade	2000-2021
01355001	-13,5564	-55,3317	Sorriso	1985-2021	01752002	-17,6889	-52,9833	Mineiros	1981-2022
01356002	-13,8156	-56,1222	Nova Mutum	1985-2022	01753000	-17,3000	-53,2194	Alto Araguaia	1981-2022
01356004	-13,4450	-56,7275	São José do Rio Claro	2004-2022	01753002	-17,3528	-53,0919	Santa Rita do Araguaia	1981-2022
01357000	-13,0661	-57,1133	Nova Maringá	1982-2022	01754000	-17,2078	-54,1400	Itiquira	1981-2022
01357001	-13,6922	-57,8944	Campo Novo do Parecis	2000-2022	01754002	-17,5869	-54,7567	Sonora	1982-2022
01358001	-13,6414	-58,2892	Campo Novo do Parecis	1983-2022	01755000	-17,4917	-55,2322	Itiquira	1981-2018
01358002	-13,4667	-58,9750	Sapezal	1983-2022	01755003	-17,2017	-56,0086	Barão de Melgaço	1981-2022
01358005	-13,9100	-58,8981	Sapezal	2000-2022	01756000	-17,0572	-56,5856	Barão de Melgaço	1981-2022
01358007	-13,0239	-58,1889	Campo Novo do Parecis	2005-2022	01756001	-17,2914	-56,3847	Barão de Melgaço	1981-2022
01359000	-13,1831	-59,8769	Comodoro	1983-2022	01756003	-17,6233	-56,9650	Corumbá	1981-2022
01359001	-13,7781	-59,7675	Comodoro	1983-2022	01757001	-17,1433	-57,3594	Pocóné	1994-2022
01360000	-13,1142	-60,5483	Colorado do Oeste	1983-2022	01757003	-17,6414	-57,6906	Corumbá	1995-2022
01360003	-13,7306	-60,5883	Comodoro	2000-2021	01853000	-17,8111	-53,2889	Alto taquari	1981-2022
01360004	-13,5033	-60,5117	Cabixi	2011-2022	01857001	-18,0403	-57,4908	Corumbá	1982-2022

Fonte: Elaborado pelos autores (2024).

O download das séries históricas das estações pluviométricas listadas na Tabela 2 foi realizado com o auxílio do plugin do QGIS intitulado ANA Data Acquisition (HGE-IPH, 2024). Após o download, as séries históricas foram processadas utilizando rotinas desenvolvidas no software MATLAB, visando a remoção de inconsistências e falhas. Com essa rotina, foi possível constituir a série histórica diária, de totais mensais e de totais mensais médios históricos de precipitação (mm).

Para a formação da série histórica de precipitação estimada por sensoriamento remoto foi utilizado o produto CHIRPS Daily: Climate Hazards Group InfraRed Precipitation With Station Data 2.0. A metodologia empregada para a validação do CHIRPS foi a de pixel para ponto. Dessa forma, foram considerados para a extração da série histórica os pixels onde estavam localizados os as estações pluviométricas (Tabela 2).

Para realizar esse procedimento utilizou-se o Geemap, um pacote Python para análise geoespacial interativa e visualização com o Google Earth Engine (GEE), desenvolvido por Wu (2020). A coleção de imagens do GEE utilizada foi a "UCSB-CHG/CHIRPS/DAILY" (Funk et al., 2015) com resolução espacial de 5.566,0 metros. As séries históricas diárias extraídas para cada pixel referente às coordenadas das estações pluviométricas foram exportadas como arquivos no formato csv. Após a exportação, essas séries passaram por uma análise semelhante à dos dados das estações, utilizando rotinas em MATLAB para remoção de inconsistências e formação dos totais diários, totais mensais e totais médios mensais históricos de precipitação.

Segundo Aksu e Akgül (2020), o CHIRPS é um produto de precipitação desenvolvido pelo Climate Hazards Groups da Universidade da Califórnia e pelo US Geological Survey. Os dados são produto de reanálise que abrange o período de 1981 até o presente, combinando dados de sensores infravermelhos de satélites, medições indiretas de chuvas baseadas em satélites das missões Tropical Rainfall Measuring Mission (TRMM) e Global Precipitation Measurement (GPM), e dados de estações de superfície para fazer a estimativa da precipitação.

Ao final do processo descrito, foi possível criar um banco de dados para as 154 localidades das estações pluviométricas (Tabela 2), contendo as séries históricas diárias de precipitação, os totais mensais e os totais médios mensais históricos de precipitação, tanto observados quanto estimados com o produto CHIRPS.

2.3 Métricas de Erro

Para validar o produto CHIRPS para o Estado de Mato Grosso utilizou-se as seguintes métricas estatísticas: erro absoluto médio (Equação 1); raiz do erro quadrático médio (Equação 2); viés (bias) (Equação 3); índice de concordância de Willmott (Equação 4), índice de eficiência de Nash-Sutcliffe (Equação 5) e o índice de eficiência de Kling-Gupta (Equação 6). A seleção dessas métricas foi baseada nos métodos utilizados por Sousa Júnior et al. (2024) e Ramos Filho et al. (2024) para avaliar o desempenho de modelos hidrológicos.

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

$$RMSE = \left[\frac{1}{N} \sum_{i=1}^N (O_i - P_i)^2 \right]^{0,5} \quad (2)$$

$$bias = \frac{1}{N} \sum_{i=1}^N (O_i - P_i) \quad (3)$$

$$d = 1 - \left[\frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (|P_i - O| + |O_i - O|)^2} \right] \quad (4)$$

$$E_{NS} = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - O)^2} \quad (5)$$

$$E_{kg} = 1 - \sqrt{(r-1)^2 + \left(\frac{\sigma_e}{\sigma_o} - 1\right)^2 + (bias-1)^2} \quad (6)$$

em que P_i é a precipitação estimada com o CHIRPS (mm); O_i , a precipitação observada (mm); O , a média da precipitação observada (mm); n , o número de valores da amostra; r é o coeficiente de correlação entre os dados observados e estimados; σ_e é o desvio padrão dos dados estimados com o CHIRPS; e σ_o é o desvio padrão dos dados observados.

Para avaliar o desempenho do produto CHIRPS com relação ao índice de eficiência de Nash-Sutcliffe (E_{NS}) foi adotada a classificação sugerida por Van Liew et al. (2007). De acordo com a classificação: $E_{NS} = 1$ significa ajuste perfeito dos dados preditos pelo modelo (CHIRPS); $E_{NS} > 0,75$ indica que o modelo é adequado e bom; $0,36 < E_{NS} < 0,75$ indica que o modelo é considerado satisfatório; $E_{NS} < 0,36$ indica que o modelo não é satisfatório. Neste trabalho, a classificação apresentada foi adotada também para avaliar o desempenho do produto CHIRPS com relação ao índice de eficiência de Kling-Gupta (E_{kg}).

O valor de “d” (Equação 4) varia entre 0 e 1, sendo que valores próximos a unidade indicam concordância, ou seja, melhor o desempenho do CHIRPS na predição. O viés foi utilizado para verificar a existência de subestimativa (valor positivo) ou superestimativa (valor negativo) pelo modelo.

A partir da validação dos dados CHIRPS foram elaborados, com auxílio do Google Earth Engine, mapas da precipitação mensal e anual média no Estado de Mato Grosso para o período de 1991 a 2020, período da última normal climatológica estabelecida pela Instituto Nacional de Meteorologia (INMET).

3. DESENVOLVIMENTO

3.1 Validação dos dados CHIRPS

Nas Figuras 2 e 3 são apresentadas as métricas de erro obtidas a partir da comparação dos dados estimados com o produto de sensoriamento remoto CHIRPS com os dados observados de precipitação observados nas estações pluviométricas localizadas no Mato Grosso. Na Figura 2 fica evidente que os melhores desempenhos de estimativa da chuva com o CHIRPS ocorrem na média histórica para o total mensal (Figura 2), com os índices de eficiência de Nash-Sutcliffe (E_{NS}) e de Kling-Gupta (E_{kg}) apresentando valores superiores a 0,75 para todo o estado. Apenas em algumas localidades o E_{kg} resultou em desempenho satisfatório ($0,36 < E_{kg} < 0,75$). Valores desses índices superiores a 0,75 indicam que o desempenho do produto CHIRPS para estimativa da precipitação total mensal histórica é “adequado e bom”, conforme a classificação de Van Liew et al. (2007).

Para os mesmos dados, o índice de concordância de Willmott (d) corrobora os

resultados obtidos com o E_{NS} e o E_{kg} . Analisando a Figura 2, observa-se que na localidade de uma das estações pluviométricas dos equipamentos os dados CHIRPS apresentaram valores entre 0,85 e 0,95. Nas demais localidades (98%), os valores de “d” ficaram superiores a 0,95, o que demonstra a estimativa adequada da chuva pelo produto de sensoriamento remoto CHIRPS.

Quanto ao viés do dado médio histórico mensal de precipitação verificou-se que, em aproximadamente 53% das localidades das estações pluviométricas, o CHIRPS superestimou a precipitação média histórica. Considerando a localização das estações pluviométricas nos biomas de Mato Grosso, o CHIRPS superestimou os dados de 66, 55 e 75% das estações pluviométricas da Amazônia, Cerrado e Pantanal, respectivamente.

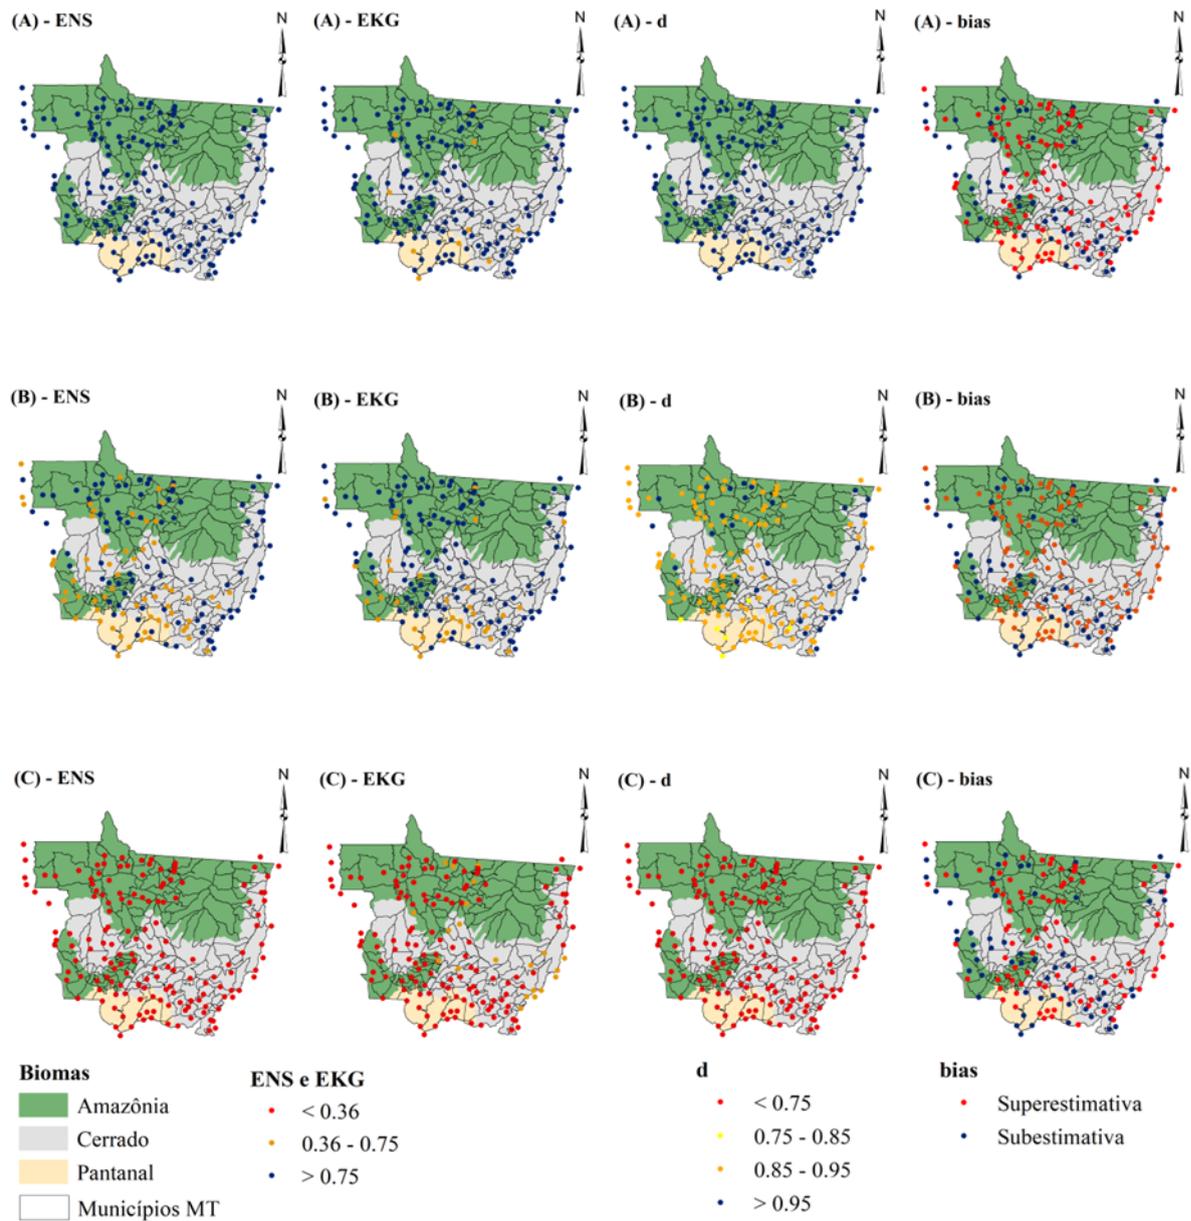
Ao realizar a análise do MAE e RMSE (Figura 3), verificou-se que apresentaram valores médios de 15,17 e 21,14 mm, respectivamente, para o total mensal histórico. Em termos de comparação, esses valores correspondem, em média, a 11% e 16% dos valores médios observados nas estações, para o MAE e o RMSE, respectivamente. Considerando todas as métricas de erro para o total mensal médio, pode-se afirmar que o produto CHIRPS é uma excelente opção para estimativa desse dado em locais sem monitoramento pluviométrico, bem como para a análise da distribuição espacial da precipitação média histórica no Estado de Mato Grosso.

Ao analisar o desempenho do CHIRPS na estimativa do total mensal, verifica-se um aumento do erro em relação à média histórica, no entanto, as estimativas de chuva por sensoriamento remoto ainda são uma ferramenta válida. Observa-se na Figura 2 que 63% dos valores de E_{NS} no bioma Amazônia ficaram acima de 0,75 (“Adequado e Bom”) e 36% entre 0,36 e 0,75, indicando desempenho “Satisfatório”. No Cerrado, esses percentuais foram semelhantes aos da Amazônia, mas, no Pantanal, foram de 30% e 65% para “Adequado e Bom” e “Satisfatório”. No geral, o E_{NS} foi superior a 0,75 em 58% das estações pluviométricas avaliadas.

Quanto ao E_{kg} para o total mensal, 76% das localidades apresentaram valores superiores a 0,75. Na Amazônia e no Cerrado 17% e 19% das localidades, respectivamente, apresentaram E_{kg} entre 0,36 e 0,75 (desempenho “Satisfatório”), enquanto as demais localidades desses biomas apresentaram E_{kg} superior a 0,75. No Pantanal, o E_{kg} para o total mensal apresentou valor “Satisfatório” para 50% das localidades e “Adequado e Bom” para

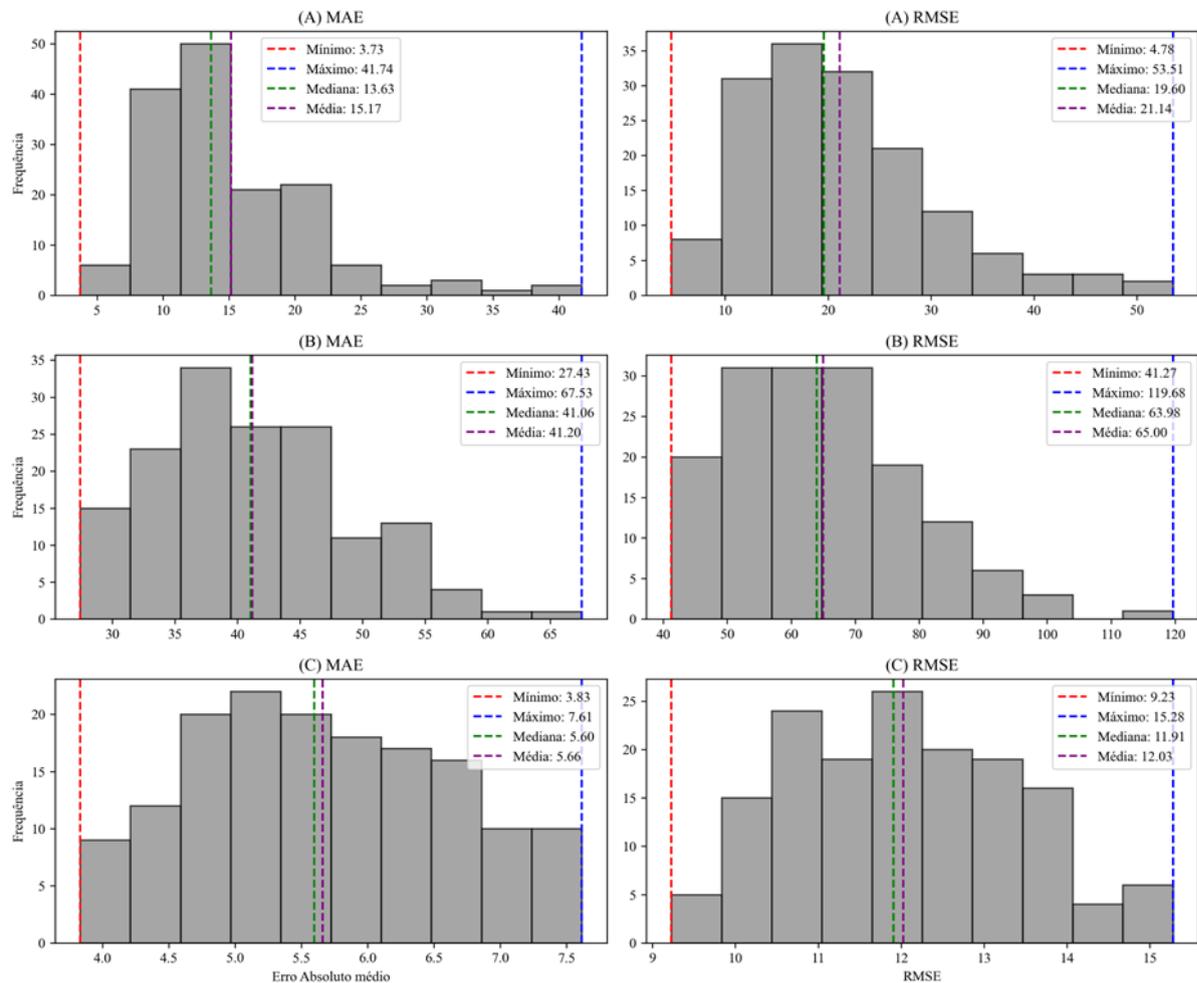
45%.

Figura 2 - Valores de índice de eficiência de Nash-Sutcliffe (E_{NS}), Kling-Gupta (E_{kg}), índice de concordância de Willmott (d) e viés (bias) para os totais médios mensais históricos (A), totais mensais (B) e totais diários (C) de precipitação oriundos do produto de sensoriamento remoto CHIRPS em comparação aos dados observados nas estações pluviométricas.



Fonte: Elaborado pelos autores (2024).

Figura 3 - Erro absoluto médio (MAE) e raiz do erro quadrático médio (RMSE) para os totais médios mensais históricos (A), totais mensais (B) e totais diários (C) de precipitação oriundos do produto de sensoriamento remoto CHIRPS em comparação aos dados observados nas estações pluviométricas.



Fonte: Elaborado pelos autores (2024).

Quanto ao índice de concordância de Willmott (d) para os totais mensais, a maior parte dos valores (74%) ficou entre 0,85 e 0,95, e 14% foram superiores a 0,95. No que diz respeito ao MAE e RMSE (Figura 3-B), para o total mensal de chuva estimado com o CHIRPS os valores apresentados foram de 41,20 e 65,00 mm, respectivamente. Além disso, ao analisar a Figura 2 percebe-se que o viés indicou superestimativa do total mensal de chuva pelo CHIRPS em 62% das localidades e subestimativa em 32% delas. De forma geral, ao se analisar as métricas de erro para o total mensal percebe-se uma redução no desempenho do produto CHIRPS em comparação ao total médio histórico. No entanto, ainda se mantém um nível aceitável para estimativa da chuva com discretização mensal.

Para os totais diários de chuva as estimativas do produto CHIRPS apresentaram

resultados insatisfatórios, com valores médios de MAE e RMSE (Figura 3 – C) de 5,66 e 12,03 mm, respectivamente, e, em termos comparativos, superaram os totais médios diários observados nas estações pluviométricas.

Ao analisar os valores de E_{NS} e E_{kg} para os totais diários (Figura 2 – C) verifica-se que os valores dessas métricas ficaram abaixo de 0,36 em 100% das localidades analisadas, o que indica que a estimativa do CHIRPS não é satisfatória. Os valores obtidos para o índice de Willmott corroboram o baixo desempenho da estimativa. O viés indicou superestimativa em 60% das localidades e subestimativa em 40%, semelhante ao obtido para os totais mensais e totais médios históricos.

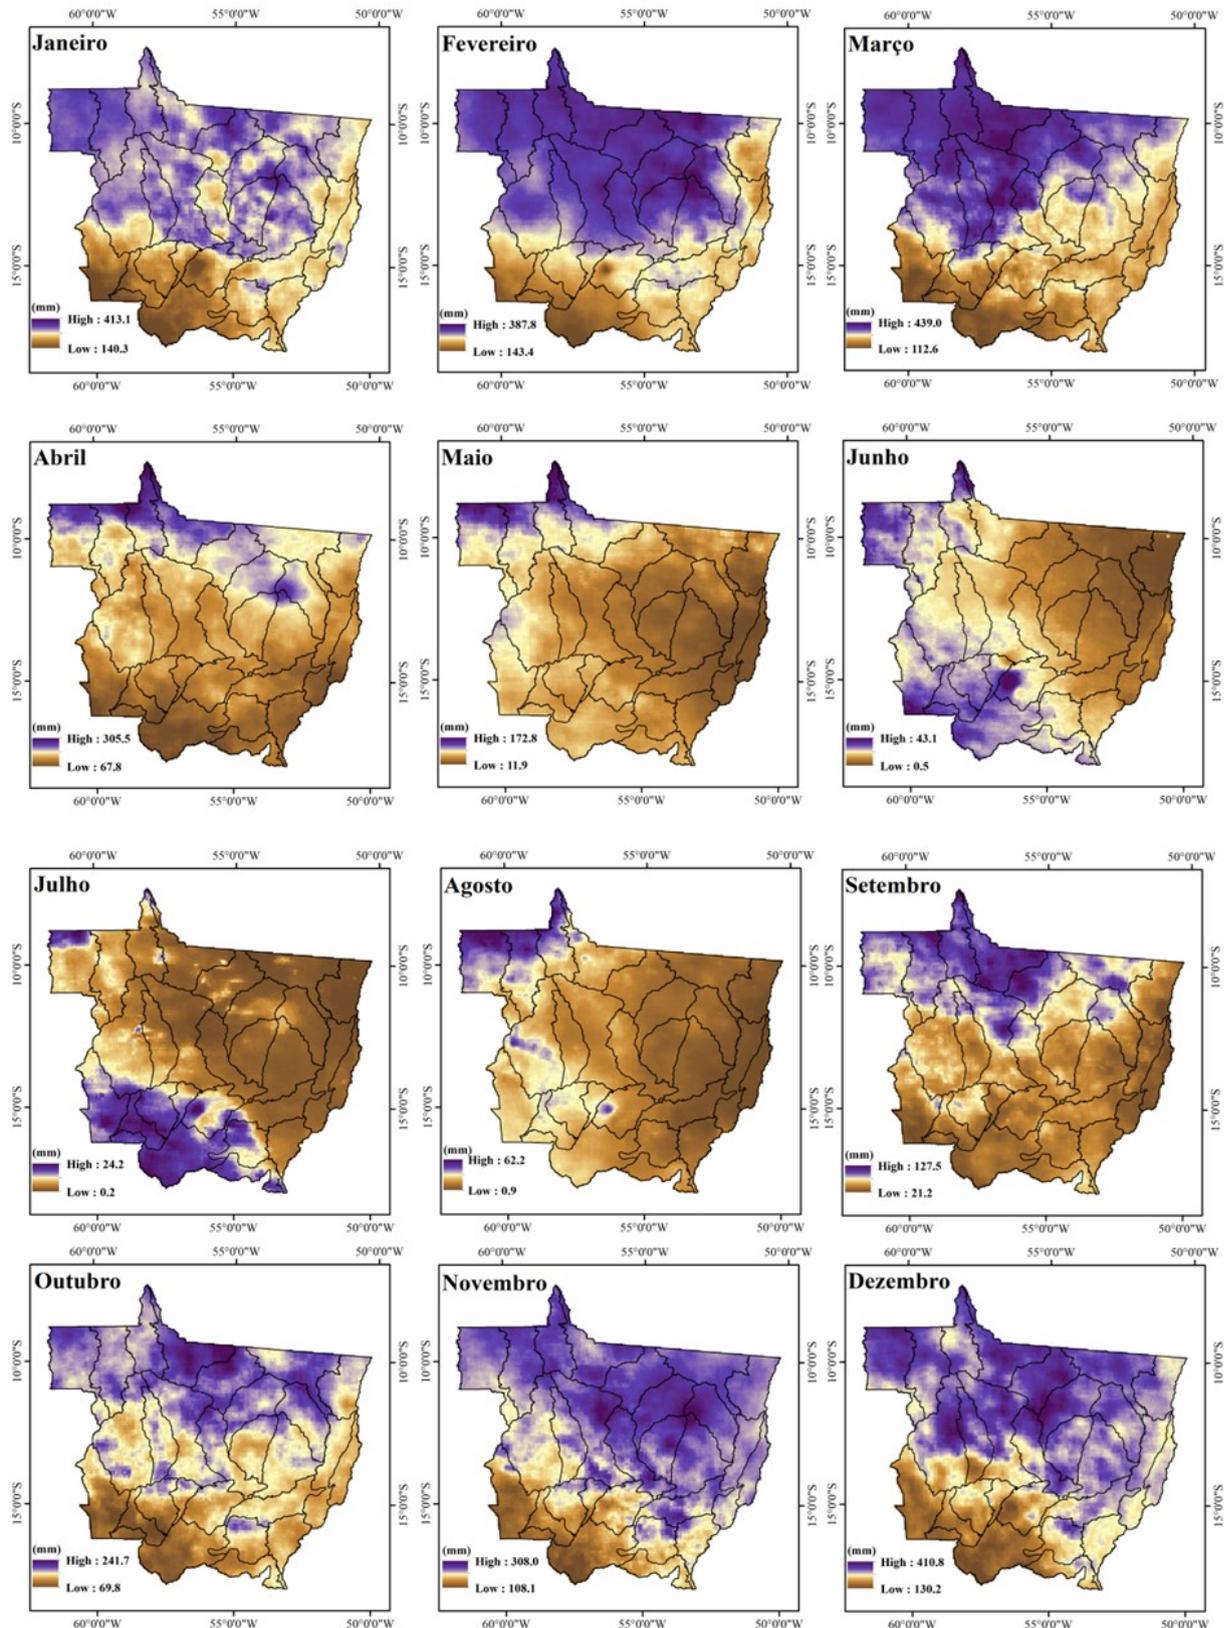
3.2 Totais Médios Mensais e Anuais por UPG

Nas Figuras 4 e 5 são apresentados os totais médios mensais e anuais de precipitação estimados com o CHIRPS para o período de 1991 a 2020. Observa-se que os maiores totais precipitados ocorrem entre outubro e abril, enquanto os menores valores ocorrem entre maio e setembro. O trimestre mais chuvoso é composto por janeiro, fevereiro e março e o trimestre com menor precipitação inclui junho, julho e agosto.

Em relação à distribuição espacial, percebe-se que os maiores totais de precipitação mensal e anual ocorrem nas bacias do bioma Amazônia, seguidas pelas áreas do Cerrado e do Pantanal. Observa-se também que a Unidade de Planejamento e Gestão de Recursos Hídricos (UPG) inserida no Pantanal possui a menor precipitação média mensal e anual comparativamente às outras UPGs de Mato Grosso (Figuras 4 e 5).

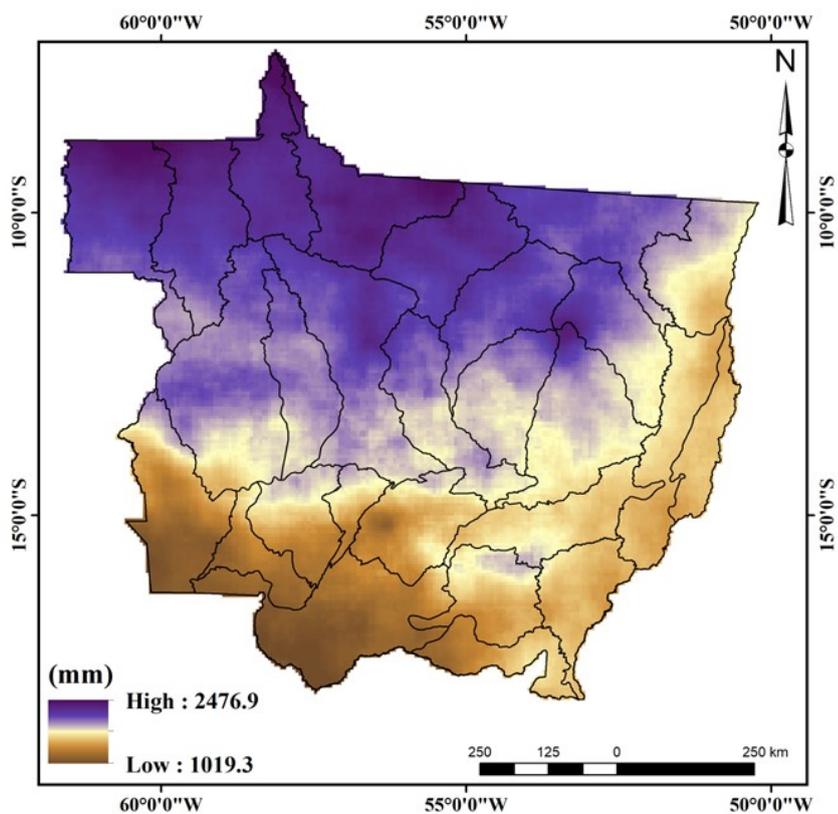
Para a análise da precipitação em termos quantitativos foram elaborados gráficos com as médias mensais e anuais de chuva por biomas, os quais estão apresentados na Figura 6. A análise desta Figura confirma que o período de maior precipitação ocorre entre outubro e abril e o de menor entre maio e setembro, para os biomas Amazônia e Cerrado. Os meses de abril e outubro podem ser considerados meses de transição entre os dois períodos.

Figura 4 - Distribuição espacial da precipitação média mensal (1991-2020) obtida a partir do produto de sensoriamento remoto CHIRPS para o estado de Mato Grosso.



Fonte: Elaborado pelos autores (2024).

Figura 5 - Distribuição espacial da precipitação média anual (1991-2020) obtida a partir do produto de sensoriamento remoto CHIRPS para o estado de Mato Grosso.



Fonte: Elaborado pelos autores (2024).

Na Amazônia, no período de outubro a abril, a precipitação média mensal varia entre 163,4 e 320,8 mm. Os meses de dezembro a março possuem as maiores precipitações médias do bioma, com valores próximos a 300,0 mm. Entre maio e setembro a precipitação varia entre 5,2 e 75,5 mm (Figura 6).

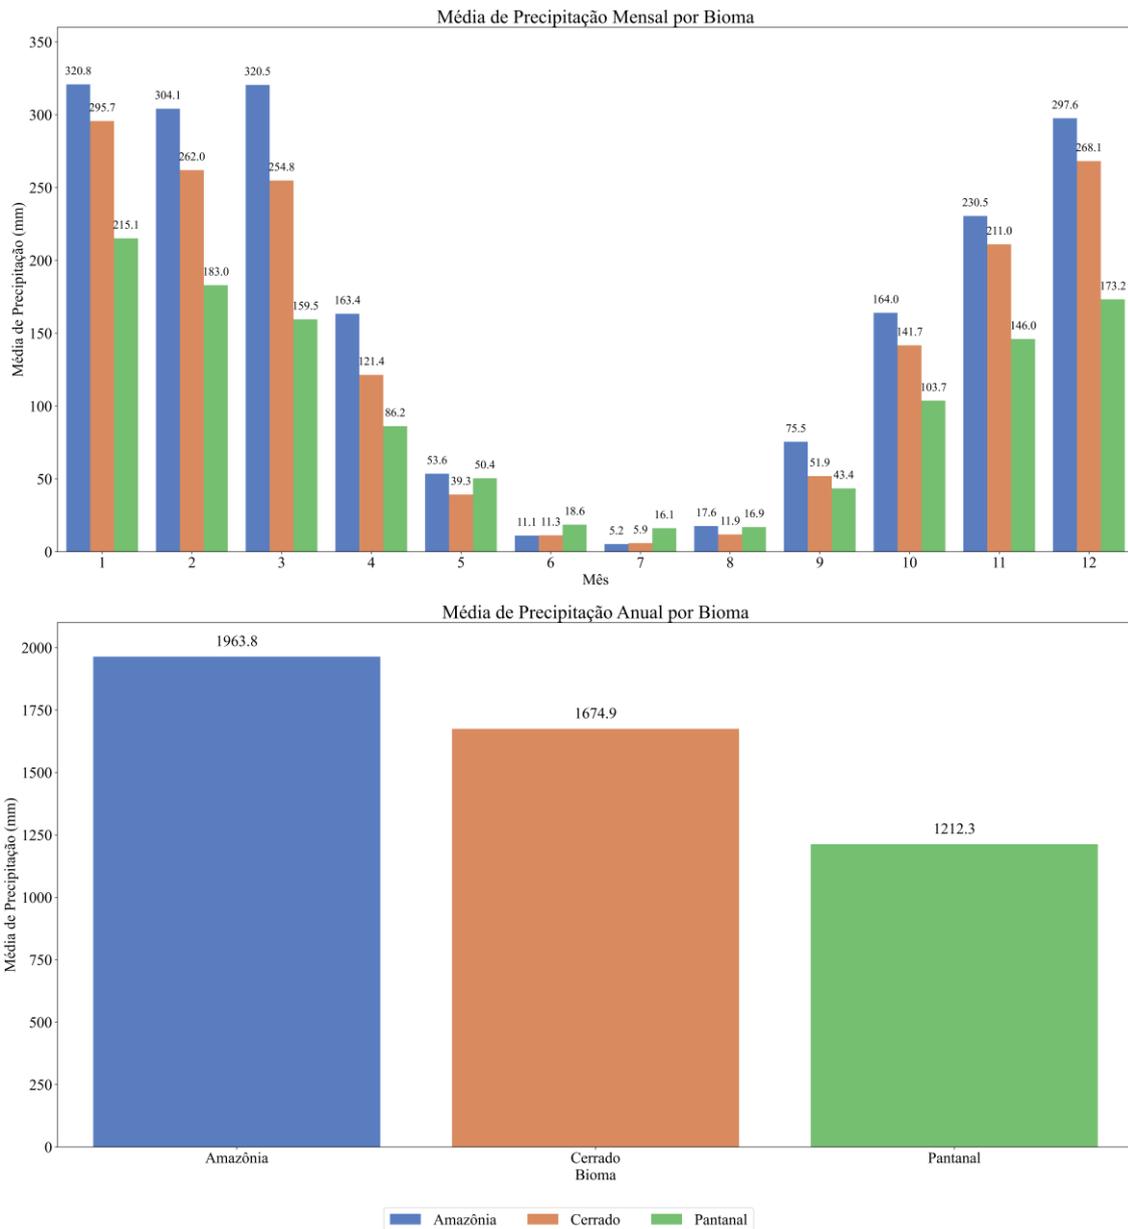
Nas áreas de Cerrado do Estado de Mato Grosso a precipitação média mensal varia entre 121,4 e 295,7 mm entre outubro e abril, e entre 5,9 e 51,9 mm no período de maio a setembro. No mesmo período, a chuva varia entre 16,1 e 50,4 mm no Pantanal e entre 86,2 e 215,1 mm no período de outubro a abril (Figura 6).

Ao analisar apenas os valores absolutos da Figura 6, pode-se afirmar que janeiro é o mês com a maior precipitação nos biomas e julho o mês com a menor. Ao analisar os valores de evapotranspiração estimados por Biudes et al. (2022), verifica-se que a precipitação que ocorre entre maio e setembro nos diferentes biomas do Estado de Mato Grosso não supre a demanda, havendo com isso déficit hídrico neste período.

Quanto às precipitações anuais médias, verifica-se que o maior valor ocorre na

Amazônia, próximo a 2.000,0 mm. Já o menor valor ocorre no Pantanal, com média de aproximadamente 1200,0 mm. O Cerrado apresentou valor médio anual de precipitação próximo a 1.700,0 mm (Figura 6).

Figura 6 - Precipitação média mensal e anual (1991-2020) para os biomas do estado de Mato Grosso estimadas a partir do produto de sensoriamento remoto CHIRPS.



Fonte: Elaborado pelos autores (2024).

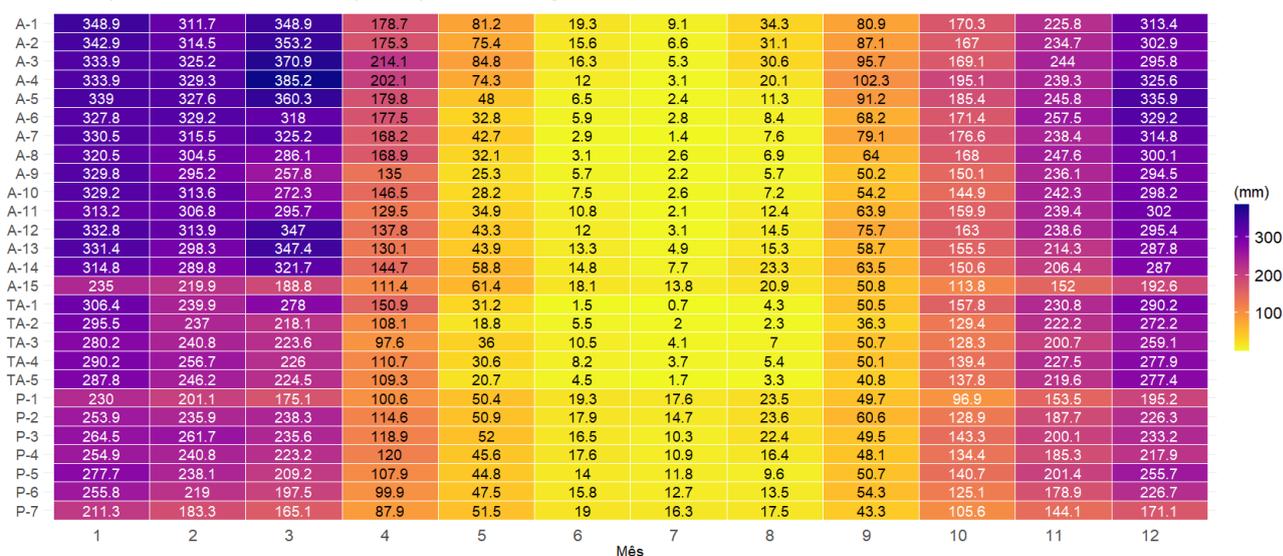
Na Figura 7 e Tabela 3 são apresentadas as médias mensais e anuais de precipitação das Unidades de Planejamento e Gestão de Recursos Hídricos (UPGs) do estado de Mato Grosso. A análise da sazonalidade das precipitações nas UPGs segue o mesmo padrão

observado para os diferentes biomas, com os maiores totais de precipitação ocorrendo entre outubro e abril e os menores entre maio e setembro. Fica evidente também nas Figuras que os maiores totais de chuva ocorrem nas UPGs da bacia amazônica (A1-A15), enquanto os menores totais ocorrem nas UPGs Paraguai (P-1 a P-7), inseridas no Pantanal. As UPGs do Tocantins-Araguaia (TA-1 a TA-5) possuem valores intermediários em relação às UPGs mencionadas anteriormente.

É importante destacar que algumas UPGs que fazem parte do bioma Amazônia estão inseridas no Cerrado e na região de transição entre Cerrado e Amazônia. Da mesma forma, as UPGs da região do Pantanal também têm parte de suas áreas localizadas no Cerrado. Entretanto, as UPGs da bacia do Tocantins-Araguaia estão integralmente situadas no bioma Cerrado.

A Figura 7 é fundamental para a consulta e análise detalhada das médias mensais e anuais de precipitação por UPGs, proporcionando uma melhor compreensão da distribuição espacial e temporal das chuvas nas bacias do estado de Mato Grosso. Essa informação é crucial para o cálculo da potencialidade hídrica das UPGs, bem como em estudos de balanço hídrico, para fins de gestão de recursos hídricos e para a elaboração de estratégias de planejamento que considerem as especificidades de cada região.

Figura 7 - Precipitação média mensal (1991-2020) estimada a partir do produto de sensoriamento CHIRPS para as unidades de planejamento e gestão de recursos hídricos do Estado de Mato Grosso.



Fonte: Elaborado pelos autores (2024).

Tabela 3 - Precipitação média anual (1991-2020) derivada do produto de sensoriamento CHIRPS para as unidades de planejamento e gestão de recursos hídricos (UPGs) do Estado de Mato Grosso

UPG	A-1	A-2	A-3	A-4	A-5	A-6	A-7	A-8	A-9	A-10	A-11	A-12	A-13	A-14
(mm)	2122,5	2106,2	2185,5	2222,2	2133,1	2028,7	2002,9	1904,5	1787,4	1846,6	1870,4	1977	1900,6	1883,1
UPG	A-15	TA-1	TA-2	TA-3	TA-4	TA-5	P-1	P-2	P-3	P-4	P-5	P-6	P-7	
(mm)	1378,3	1742,1	1547,4	1626,3	1538,8	1573,5	1312,9	1553,2	1608,1	1515,2	1561,5	1446,8	1216,0	

Fonte: Elaborado pelos autores (2024).

Com base nos resultados apresentados fica evidente que o CHIRPS é um produto promissor para estimar a precipitação e analisar sua distribuição espacial e temporal no estado de Mato Grosso. Porém, essa evidência é válida apenas para os totais médios mensais históricos de chuva e para os totais mensais. Nesta escala de tempo, os resultados obtidos com a aplicação das métricas de desempenho estatístico são semelhantes àqueles obtidos por Silva et al. (2020) e Paredes-Trejo; Barbosa; Kumar (2017) na Amazônia e no Nordeste brasileiro, respectivamente.

Para as estimativas de precipitação diária o desempenho do CHIRPS foi insatisfatório em todas as localidades de Mato Grosso, indicando uma baixa precisão e acurácia do produto nessa escala temporal. Estudos como os de Aksu; Akgül (2020), Alsilibe et al. (2023) e Saragih et al. (2022) também apontam para um desempenho inferior do CHIRPS em escalas diárias, sugerindo a necessidade de uma validação local mais robusta.

Apesar do baixo desempenho em escala diária, isso não necessariamente invalida os dados do CHIRPS para essa escala temporal, visto que existe um fator de incerteza ao se utilizar a metodologia ponto para pixel, considerando apenas a chuva medida em um ponto específico e comparando-se com a chuva estimada pelo CHIRPS para uma área de aproximadamente 25 km². Maggioni e Massari (2018) destacam que as estimativas de chuva por sensoriamento remoto devem ser corrigidas e validadas regionalmente, e os erros associados podem ser minimizados durante o processo de calibração de modelos hidrológicos, tornando-se, mesmo em escala temporal diária, ferramentas válidas em estudos de previsão hidrológica.

No que se refere ao viés, ficou clara a ocorrência de superestimativas no estado de Mato Grosso com o uso do CHIRPS. Ao comparar os resultados obtidos neste trabalho com os da literatura, como os de Alsilibe et al. (2023), Dinku et al. (2018), Fessehaye; Franke; Bronnimann (2022), Paredes-Trejo; Barbosa; Kumar (2020) e Silva et al. (2020), verificou-se

que a superestimativa ou subestimativa da precipitação depende da localidade estudada e da sazonalidade. Portanto, é necessário comparar as estimativas do CHIRPS com os dados coletados na superfície para cada localidade.

Fessehaye; Franke; Bronnimann (2022), ao validarem os dados CHIRPS para a Eritreia, observaram que o produto apresentou superestimativas, principalmente em áreas convectivas durante o verão, e subestimativas em áreas subúmidas no inverno. Sistemas convectivos têm uma forte influência nas chuvas em Mato Grosso, conforme destacado no estudo de Carvalho et al. (2022), que analisou os sistemas sinóticos que afetam a precipitação no estado. Assim, essa pode ser uma das causas das superestimativas observadas, no entanto, análises mais detalhadas são necessárias para confirmar essa hipótese.

Por outro lado, Katsanos; Retalis; Michaelides (2016), ao validarem o produto CHIRPS para o Chipre, identificaram uma tendência de superestimativa da precipitação na última década do período estudado. Os autores sugerem que esse comportamento pode estar relacionado à incorporação das estimativas do TRMM, que tendem a superestimar a precipitação. Ghozat; Sharafati; Hosseini (2022) ao analisar o produto CHIRPS no Irã verificaram que o produto tendeu a subestimar a precipitação antes de 1998 e a superestimar após a 1998, porém não sugeriram motivo para esse comportamento.

Os resultados demonstraram que o produto CHIRPS possui potencial para ser utilizado no Estado de Mato Grosso na gestão de recursos hídricos, estimativa do balanço hídrico e monitoramento de secas, sobretudo em regiões remotas do estado ou onde o monitoramento das precipitações é deficiente. Contudo, vale destacar que as informações do CHIRPS devem ser interpretadas com a compreensão de suas limitações em diferentes contextos regionais e temporais.

No que tange à utilização do CHIRPS para o monitoramento de secas, Carvalho et al. (2020) já haviam confirmado essa possibilidade para a região médio-norte de Mato Grosso, localizada em uma área de transição entre o Cerrado e a Amazônia. Segundo esses autores, o produto CHIRPS permite o monitoramento e a análise espacial de forma eficaz da seca meteorológica durante o desenvolvimento da soja e do milho na região. Essa informação é primordial para fins de seguro agrícola e para o direcionamento de ações de mitigação desse evento extremo.

Ghozat; Sharafati; Hosseini (2022) ao fazer análise do produto CHIRPS para

monitoramento de secas no Irã corroboram os resultados obtidos pelos autores mencionados anteriormente. Conforme esses autores o CHIRPS mostrou boa capacidade para detectar eventos de secas em diferentes escalas temporais, especialmente na mensal (SPI1) e trimestral (SPI3).

A validação do produto realizada neste estudo para Mato Grosso servirá como base para outros trabalhos importantes no Estado, como a detecção de secas com sensoriamento remoto, a análise de tendência da precipitação, semelhante à realizada por Paca et al. (2020) para a bacia Amazônica, bem como a avaliação do impacto das mudanças no uso e cobertura da terra nos totais precipitados. Hsu et al. (2021) destacam que uma das vantagens do produto CHIRPS em relação a outros produtos de chuva por sensoriamento remoto está no fato de possuir uma série longa com início em 1981, o que permite analisar tendências e avaliar o impacto das alterações no meio físico e das mudanças climáticas no total precipitado de uma região.

4. CONSIDERAÇÕES FINAIS

A partir dos resultados obtidos pode-se concluir que:

- O produto CHIRPS estima de forma adequada a precipitação total mensal e a média histórica mensal no estado do Mato Grosso, revelando-se uma ferramenta promissora para a gestão de recursos hídricos, detecção de secas, estudos de balanço hídrico e modelagem hidrológica de bacias hidrográficas;
- Para totais precipitados diários o erro de estimativa do CHIRPS é elevado, não sendo recomendada sua utilização de forma direta sem correção dos dados ou calibração em modelos hidrológicos;
- O CHIRPS constitui-se numa excelente ferramenta para estimativa de chuva em locais com monitoramento deficiente, situação comum no Estado de Mato Grosso, que possui uma rede pluviométrica esparsa e que não contempla de forma adequada todas as áreas de interesse para fins de planejamento e gestão de recursos hídricos;
- O bioma Amazônia e, conseqüentemente, as Unidades de Planejamento de Gestão de Recursos Hídricos (UPGs) nele inseridas, apresenta a maior precipitação do estado, seguido

pelas áreas de Cerrado. Já o bioma Pantanal possui a menor precipitação média mensal e anual em comparação aos outros biomas do Estado.

- O período de maior precipitação em todo o Estado de Mato Grosso ocorre entre outubro e abril, enquanto o período de menor precipitação vai de maio a setembro. Durante este período seco, a precipitação não atende à demanda evapotranspirométrica nos diferentes biomas, havendo, portanto, déficit hídrico. Os meses de abril e outubro podem ser considerados de transição entre os períodos chuvoso e seco. Os meses de dezembro a março são os mais chuvosos em todo o estado.

REFERÊNCIAS

AKSU, H.; AKGÜL, M. A. Performance evaluation of CHIRPS satellite precipitation estimates over Turkey. **Theoretical and Applied Climatology**, v. 142, p. 71-84, 2020. <https://doi.org/10.1007/s00704-020-03301-5>

ALEJO, L. A.; ALEJANDRO, A. S. Validating CHIRPS ability to estimate rainfall amount and detect rainfall occurrences in the Philippines. **Theoretical and Applied Climatology**, v. 145, n. 3-4, p. 967-977, 2021. <https://doi.org/10.1007/s00704-021-03685-y>

ALSILIBE, F.; BENE, K.; BILAL, G.; ALGHAFI, K.; SHI, X. Accuracy Assessment and Validation of Multi-Source CHIRPS Precipitation Estimates for Water Resource Management in the Barada Basin, Syria. **Remote Sensing**, v. 15, n. 7, p. 1778, 2023. <https://doi.org/10.3390/rs15071778>

ANA (Brasil) Agência Nacional de Águas. Polos Nacionais de Irrigação: Mapeamento de Áreas Irrigadas com Imagens de Satélite. 2020. Disponível em: <https://cdn.agenciapeixe vivo.org.br/media/2020/03/polos-nacionais-irriga%C3%A7%C3%A3o.pdf>. Acesso em: 06 jun. 2024.

BIUDES, M. S., GELI, H. M., VOURLITIS, G. L., MACHADO, N. G., PAVÃO, V. M., DOS SANTOS, L. O. F., QUERINO, C. A. S. Evapotranspiration seasonality over tropical ecosystems in Mato Grosso, Brazil. **Remote Sensing**, v. 14, n. 10, p. 2482, 2022. <https://doi.org/10.3390/rs14102482>

CARVALHO, M. A. C. C.; ULIANA, E. M.; SILVA, D. D.; AIRES, U. R. V.; MARTINS, C. A. S.; SOUSA JUNIOR, M. F.; CRUZ, I. F.; MENDES, M. A. S. A. Drought monitoring based on remote sensing in a grain-producing region in the cerrado–amazon transition, Brazil. **Water**, v. 12, n. 12, p. 3366, 2020. <https://doi.org/10.3390/w12123366>

CARVALHO, M. A. C. C.; ULIANA, E. M.; SILVA, B. F. P.; MARTINS, C. A. S.; CRUZ, I. F.; AIRES, U. R. V.; MENDES, M. A. S. A. Precipitação Provável de uma importante região produtora de grãos do Brasil: probabilidade, distribuição espacial e sistemas sinóticos. **Geo UERJ**, n. 41, p. e52331, 2022. DOI: 10.12957/geouerj.2022.52331.

DINKU, T.; FUNK, C.; PETERSON, P.; MAIDMENT, R.; TADESSE, T.; GADAIN, H.; CECCATO, P. Validation of the CHIRPS satellite rainfall estimates over eastern Africa. **Quarterly Journal of the Royal Meteorological Society**, v. 144, p. 292-312, 2018. <https://doi.org/10.1002/qj.3244>

FESSEHAYE, M.; FRANKE, J.; BRÖNNIMANN, S. Evaluation of satellite-based (CHIRPS and GPM) and reanalysis (ERA5-Land) precipitation estimates over Eritrea. **Meteorologische Zeitschrift**, v. 31, n. 5, p. 401-413, 2022. <https://doi.org/10.1127/metz/2022/1111>

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**, v. 2, p. 150066, 2015. <https://doi.org/10.1038/sdata.2015.66>

GHOZAT, A.; SHARAFATI, A.; HOSSEINI, S. A. Satellite-based monitoring of meteorological drought over different regions of Iran: application of the CHIRPS precipitation product. **Environmental Science and Pollution Research**, v. 29, n. 24, p. 36115-36132, 2022. <https://doi.org/10.1007/s11356-022-18773-3>

HGE-IPH. ANA Data Acquisition. 2024. Disponível em: <https://www.ufrgs.br/hge/ana-data-acquisition/>. Acesso em: 06 jun. 2024.

HSU, JIE; HUANG, WAN RU; LIU, PIN YI; LI, XIUZHEN. Validation of chirps precipitation estimates over taiwan at multiple timescales. **Remote Sensing**, v. 13, n. 2, p. 1-18, 2021. <https://doi.org/10.3390/rs13020254>

IBGE (Brasil). Instituto Brasileiro de Geografia e Estatística. Censo Agropecuário 2017. 2017. Disponível em: <https://censoagro2017.ibge.gov.br/>. Acesso em: 06 jun. 2024.

KATSANOS, D.; RETALIS, A.; MICHAELIDES, S. Validation of a high-resolution precipitation database (CHIRPS) over Cyprus for a 30-year period. **Atmospheric Research**, v. 169, p. 459-464, 2016. <https://doi.org/10.1016/j.atmosres.2015.05.015>

JUNQUEIRA, R.; VIOLA, M. R.; AMORIM, J. S.; CAMARGOS, C.; MELLO, C. R. Hydrological modeling using remote sensing precipitation data in a Brazilian savanna basin, *Journal of South American Earth Sciences*, v. 115, 2022, <https://doi.org/10.1016/j.jsames.2022.103773>.

MELLO, C. R.; SILVA, A. M.; BESKOW, S. **Hidrologia de Superfície: princípios e aplicações**. Lavras: Editora UFLA, 2020. 531 p.

MAGGIONI, V.; MASSARI, C. On the performance of satellite precipitation products in riverine flood modeling: A review. **Journal of Hydrology**, v. 558, 2018. <https://doi.org/10.1016/j.jhydrol.2018.01.039>

NAWAZ, M.; IQBAL, M.F.; MAHMOOD, I. Validation of CHIRPS satellite-based precipitation dataset over Pakistan. **Atmospheric Research**, v. 248, 2021. <https://doi.org/10.1016/j.atmosres.2020.105289>

PACA, V. H. M.; ESPINOZA-DÁVALOS, G.; MOREIRA, D.; 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, n. 5, p. 1244, 2020. <https://doi.org/10.3390/w12051244>

PAREDES-TREJO, F. J.; BARBOSA, H. A.; KUMAR, T. V. L. Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil. **Journal of Arid Environments**, v. 139, p. 26-40, 2017. <https://doi.org/10.1016/j.jaridenv.2016.12.009>

RAMOS FILHO, H. A.; ULIANA, E. M.; AIRES, U. R. V.; CRUZ, I. F.; LISBOA, L.; SILVA, D. D.; VIOLA, M. R.; DUARTE, V. B. R. Nowcast flood predictions in the Amazon watershed based on the remotely sensed rainfall product PDIRnow and artificial neural networks. **Environmental Monitoring and Assessment**, v. 196, p. 245, 2024. <https://doi.org/10.1007/s10661-024-12396-6>

SARAGIH, N. F.; SITEPU, S.; SIMANUNGKALIT, G. T.; SINAMBELA, M.; RAJAGUKGUK, E.; LAROSA, F. G.; JAYA, I. K. Validation of CHIRPS Estimation Rainfall Data Using Numerical Accuracy Test with Precipitation Observation Data. **IOP Conference Series: Earth and Environmental Science**, v. 1083, 2022. <https://doi.org/10.1088/1755-1315/1083/1/012095>

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. 3, p. 1094-1105, 2020.

SOUSA JUNIOR, M. F.; ULIANA, E. M.; AIRES, U. R. V.; RÁPALO, L. M. C.; SILVA, D. D.; MOREIRA, M. C.; LISBOA, L.; RONDON, D. S. Streamflow prediction based on machine learning models and rainfall estimated by remote sensing in the Brazilian Savanna and Amazon biomes transition. **Modeling Earth Systems and Environment**, v. 10, p. 1191-1202, 2024. <https://doi.org/10.1007/s40808-023-01837-9>

VAN LIEW, M. W., VEITH, T. L., BOSCH, D. D., ARNOLD, J. G. Suitability of SWAT for the conservation effects assessment project: a comparison on USDA-ARS watersheds. **Journal of Hydrologic Engineering**, v. 12, n. 2, p. 173-189, 2007. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2007\)12:2\(173\)](https://doi.org/10.1061/(ASCE)1084-0699(2007)12:2(173))

WU, Q. Geemap: A Python package for interactive mapping with Google Earth Engine. 2020. Disponível em: <https://github.com/giswqs/geemap>. Acesso em: 06 jun. 2024.