



Revista Brasileira de Geografia Física

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



Avaliação de produtos de reanálise e sensoriamento remoto para estimativa da velocidade do vento no Centro-Oeste do Brasil

Juliana Barbosa da Silva Lotufo¹, Nadja Gomes Machado², Nêvio Lotufo Neto³, Luiz Octávio Fabrício dos Santos⁴, Carlos Alexandre Santos Querino⁵, Juliane Kayse Albuquerque da Silva Querino⁶, Leone Francisco Amorim Curado⁷, Marcelo Sacardi Biudes⁸

^{1,3,4} Discente de Doutorado no Programa de Pós-Graduação em Física Ambiental, Instituto de Física, Universidade Federal de Mato Grosso, Av. Fernando Corrêa da Costa, n.º2367, Cidade Universitária, Bloco de Física Ambiental, 78060-900, Cuiabá-MT, Brasil. ² Professora no Instituto Federal de Mato Grosso, Campus Cuiabá Bela Vista, Av. Juliano Costa Marques, SN, Bela Vista, 78.050-560, Cuiabá-MT, Brasil. ^{5,6} Professores no Instituto de Educação, Agricultura e Ambiente, Universidade Federal do Amazonas-UFAM, Av. General Rodrigo Octavio Jordão Ramos, 1200 - Coroado I, Manaus - AM, 69067-005. ^{7,8} Professores no Instituto de Física, Universidade Federal de Mato Grosso, Av. Fernando Corrêa da Costa, n.º2367, Cidade Universitária, Bloco de Física Ambiental, 78060-900, Cuiabá-MT, Brasil. (65) 3313-7306.

Artigo recebido em 13/02/2024 e aceito em 16/07/2025

RESUMO

A escassez de dados meteorológicos observacionais no Brasil, especialmente no Centro-Oeste, limita a compreensão da variabilidade climática regional e o desenvolvimento de aplicações como o planejamento energético. Neste estudo, avaliou-se a qualidade e a confiabilidade de cinco produtos de reanálise e sensoriamento remoto (ERA5-Land, GLDAS, JRA-55, NCEP/DOE e MERRA-2) na estimativa da velocidade do vento, comparando-os com dados observacionais de 120 estações meteorológicas automáticas entre 2000 e 2020. As comparações foram realizadas em escalas diária, mensal e anual, considerando também as características dos principais biomas da região (Amazônia, Cerrado, Pantanal e Mata Atlântica). Os resultados indicaram variações significativas no desempenho dos produtos, com o ERA5 apresentando melhor concordância com os dados observados em todas as escalas e biomas, beneficiado por sua alta resolução e assimilação de dados avançada. O GLDAS também demonstrou desempenho consistente em diversas condições, enquanto NCEP/DOE e MERRA-2 exibiram superestimação sistemática, especialmente em escalas diárias e em biomas com vegetação densa ou topografia complexa. Esses achados destacam a importância de uma seleção criteriosa de produtos de reanálise e sensoriamento remoto para aplicações regionais. Recomenda-se o uso preferencial do ERA5 para estimativas de velocidade do vento no Centro-Oeste brasileiro, com validações locais para reduzir incertezas, apoiando estudos climáticos, hidrológicos e o planejamento de infraestrutura energética.

Palavras-chave: Modelagem Atmosférica, Assimilação de Dados, Variabilidade Espacial, Energia Eólica.

Evaluation of Reanalysis and Remote Sensing Products for Wind Speed Estimation in the Brazilian Central-West

ABSTRACT

The scarcity of observational meteorological data in Brazil, especially in the Central-West region, limits the understanding of regional climate variability and hinders the development of applications such as energy planning. This study evaluated the quality and reliability of five reanalysis and remote sensing products (ERA5-Land, GLDAS, JRA-55, NCEP/DOE, and MERRA-2) for estimating wind speed by comparing them with observational data from 120 automatic weather stations between 2000 and 2020. Comparisons were performed at daily, monthly, and annual scales, also considering the characteristics of the region's main biomes (Amazon, Cerrado, Pantanal, and Atlantic Forest). The results indicated significant variations in product performance, with ERA5 showing the highest agreement with observed data across all scales and biomes, benefiting from its high spatial resolution and advanced data assimilation techniques. GLDAS also demonstrated consistent performance under various conditions, while NCEP/DOE and MERRA-2 exhibited systematic overestimation, particularly at daily scales and in biomes with dense vegetation or complex topography. These findings highlight the importance of carefully selecting reanalysis and remote sensing products for regional applications. The ERA5 product is recommended as the preferred source for wind speed estimates in the Brazilian Central-West, with local validations advised to reduce uncertainties, supporting climate studies, hydrological modeling, and energy infrastructure planning.

Keywords: Atmospheric Modeling, Data Assimilation, Spatial Variability, Wind Energy.

Introdução

A obtenção de dados meteorológicos confiáveis e espacialmente distribuídos é essencial para compreender a dinâmica atmosférica, melhorar previsões climáticas regionais e embasar estratégias de gestão ambiental e energética. No entanto, a rede meteorológica nacional brasileira, coordenada pelo Instituto Nacional de Meteorologia (INMET), apresenta distribuição desigual, com maior concentração de estações automáticas em estados como Minas Gerais e São Paulo, que juntos somam cerca de um terço das estações em operação, cobrindo apenas 20% do território nacional (Xavier et al., 2016). Em contraste, nove estados da Amazônia Legal e do Nordeste, que representam 60% do território, possuem densidade inferior a uma estação por 10.000 km² (Siefert et al., 2022). Essa disparidade gera lacunas significativas na cobertura de dados meteorológicos, limitando a análise de variáveis essenciais como a velocidade do vento.

Para contornar essa deficiência, produtos de reanálise climática e sensoriamento remoto têm sido amplamente utilizados como fontes alternativas, combinando dados observacionais, medições de satélite e modelos numéricos para gerar séries temporais consistentes no espaço e no tempo (Gelaro et al., 2017). Esses produtos são particularmente valiosos em regiões com escassez de dados *in situ*, permitindo aplicações em modelagem climática e hidrológica, previsão de eventos extremos e planejamento de infraestrutura (Teixeira de Aguiar & Lobo, 2020). Contudo, a diversidade de produtos disponíveis, cada um com diferentes resoluções espaciais e temporais, esquemas de assimilação de dados e parametrizações físicas, exige uma avaliação sistemática de sua qualidade e adequação às condições regionais específicas (Manzanas et al., 2019; Bhuiyan et al., 2019).

A região Centro-Oeste do Brasil exemplifica bem esses desafios. Caracterizada por grande extensão territorial e heterogeneidade ambiental, inclui quatro dos seis biomas brasileiros (Amazônia, Cerrado, Pantanal e Mata Atlântica) e diferentes regimes climáticos segundo Köppen, como Af (equatorial), Am (monçônico), Aw (savana) e Cwb (subtropical de altitude). Essa diversidade climática e ecológica impõe dificuldades adicionais para a representação das variáveis atmosféricas por modelos globais (de Souza et al., 2024). Estudos anteriores demonstraram que produtos de reanálise podem

apresentar discrepâncias substanciais em relação a dados observados, especialmente em escalas diárias ou em regiões com cobertura vegetal densa e topografia variada (De Aquino Ferreira et al., 2022; Mariano et al., 2017; Siefert et al., 2022). Essas diferenças decorrem de fatores como resolução espacial, parametrização da camada limite atmosférica e estratégias de assimilação de dados, impactando diretamente a aplicabilidade desses produtos para estudos climáticos regionais e planejamento de energia eólica (Fan et al., 2021; Hersbach et al., 2020).

Além disso, condições específicas como a elevada rugosidade superficial da Amazônia ou os regimes sazonais marcantes do Cerrado influenciam a variabilidade da velocidade do vento, exigindo produtos capazes de capturar tais dinâmicas para fornecer estimativas confiáveis. A falta de séries longas e consistentes de dados observados em superfície dificulta a calibração e validação dos modelos, aumentando as incertezas associadas às projeções climáticas regionais e limitando o desenvolvimento de estratégias de mitigação e adaptação.

Nesse contexto, o presente estudo tem como objetivo avaliar a qualidade e a confiabilidade de diferentes produtos de reanálise e sensoriamento remoto na estimativa da velocidade do vento no Centro-Oeste do Brasil. Para isso, comparam-se estimativas diárias, mensais e anuais de velocidade do vento obtidas de cinco produtos de reanálise e sensoriamento remoto com dados observados em 120 estações meteorológicas automáticas, considerando as características climáticas e a diversidade de biomas da região. Essa avaliação busca subsidiar a escolha adequada desses produtos para aplicações em modelagem climática, planejamento energético e gestão ambiental em regiões com cobertura observacional limitada.

Material e métodos

Área de Estudo

A região Centro-Oeste do Brasil abrange os estados de Mato Grosso (MT), Mato Grosso do Sul (MS), Goiás (GO) e o Distrito Federal (DF), onde se localiza a capital Brasília (Figura 1). Essa área apresenta grande diversidade de ecossistemas, englobando quatro dos seis biomas brasileiros: Amazônia, Cerrado, Pantanal e Mata Atlântica. Quanto ao clima, segundo a classificação de Köppen, predominam tipos variados, como Af (equatorial úmido), Am (monçônico), Aw

(savana), Cfa (subtropical úmido), Cwa (subtropical úmido com inverno seco) e Cwb (subtropical de altitude). Essa diversidade climática e ambiental reflete a complexidade dos processos atmosféricos na região, que também é um importante polo agropecuário e produtor de commodities do Brasil (Vilpoux et al., 2021).

Medições de superfície

Os dados observacionais de velocidade do vento foram obtidos a partir do Banco de Dados

Meteorológicos para Ensino e Pesquisa (BDMEP), mantido pelo Instituto Nacional de Meteorologia (INMET). Foram selecionadas 120 estações meteorológicas automáticas distribuídas pelo Centro-Oeste brasileiro (Figura 1), com séries temporais no período de 2000 a 2020. A escolha das estações considerou critérios de qualidade e consistência, limitando o percentual de dados faltantes a um máximo entre 5% e 10%.




Figura 1. Localização das estações meteorológicas automáticas (A), biomas (B) e clima (C) da região Centro-Oeste do Brasil.

As medições de velocidade do vento em todas as estações seguem as recomendações da Organização Meteorológica Mundial (OMM), sendo realizadas a 10 metros acima da superfície (Santos e Silva, 2013). Para compatibilizar esses dados com a altura de 2 metros, mais utilizada em aplicações agrônômicas e modelos de superfície, aplicou-se a conversão logarítmica com o perfil de vento descrito por Allen et al. (1998). Em seguida, os dados horários foram processados para obtenção

de médias diárias, respeitando a integridade das séries temporais e assegurando a comparabilidade com os dados dos produtos de reanálise e sensoriamento remoto.

A Tabela 1 apresenta a relação completa das estações meteorológicas automáticas utilizadas no estudo, incluindo códigos, municípios, coordenadas geográficas, clima, bioma e período de dados disponíveis.

Tabela 1 – Descrição da localização das estações meteorológicas automáticas do Centro-Oeste brasileiro, INMET.

Código da Estação	Município	Longitude	Latitude	Clima	Bioma	Disponibilidade de dados	
A001	Brasília – DF	-47.925833	-15.789444	Cwa	Cerrado	2000	2020
A002	Goiânia – GO	-49.220222	-16.642841	Aw	Cerrado	2001	2020
A003	Morrinhos – GO	-49.101698	-17.745066	Aw	Cerrado	2001	2020
A004	Niquelândia – GO	-48.485833	-14.469444	Aw	Cerrado	2001	2018
A005	Porangatu – GO	-49.1175	-13.309444	Aw	Cerrado	2001	2020
A006	Crixas – GO	-49.966667	-14.533333	Aw	Cerrado	2001	2006
A007	Faina – GO	-50.366667	-15.433333	Aw	Cerrado	2003	2005
A008	Faculdade da Terra de Brasília – GO	-48.119977	-15.907513	Cwa	Cerrado	2003	2013
A011	São Simão – GO	-50.633449	-18.969142	Aw	Mata Atlântica	2006	2020
A012	Luziânia – GO	-47.966944	-16.260556	Aw	Cerrado	2006	2020
A013	Aragarças – GO	-52.245278	-15.902778	Aw	Cerrado	2007	2020
A014	Goiás – GO	-50.141389	-15.939722	Aw	Cerrado	2007	2020
A015	Itapaci – GO	-49.54	-14.979722	Aw	Cerrado	2007	2020
A016	Jataí – GO	-51.717467	-17.923622	Aw	Cerrado	2007	2020
A017	Posse – GO	-46.366389	-14.089167	Aw	Cerrado	2007	2020
A022	Goianésia – GO	-48.99	-15.220278	Aw	Cerrado	2007	2020
A023	Caiaopônia – GO	-51.8175	-16.966944	Aw	Cerrado	2007	2020
A024	Alto Paraíso de Goiás – GO	-47.523333	-14.133056	Cwa	Cerrado	2007	2020
A025	Rio Verde – GO	-50.965	-17.785278	Aw	Cerrado	2007	2020
A026	Mineiros – GO	-52.601111	-17.454722	Aw	Cerrado	2007	2020
A027	Paraúna – GO	-50.42545	-16.962536	Aw	Cerrado	2008	2020
A028	Iporá – GO	-51.148889	-16.423056	Aw	Cerrado	2013	2020
A029	Edéia – GO	-49.914722	-17.336944	Aw	Cerrado	2017	2020
A031	São Miguel do Araguaia – GO	-50.335833	-12.820556	Aw	Cerrado	2017	2020
A032	Monte Alegre de Goiás – GO	-46.890326	-13.253521	Aw	Cerrado	2007	2020
A033	Pires do Rio – GO	-48.284167	-17.304167	Aw	Cerrado	2007	2020
A034	Catalão – GO	-47.927614	-18.154779	Cwa	Cerrado	2008	2020
A035	Itumbiara – GO	-49.191944	-18.409722	Aw	Mata Atlântica	2007	2020
A036	Cristalina – GO	-47.613056	-16.785	Cwb	Cerrado	2007	2020
A037	Silvania – GO	-48.618056	-16.679722	Aw	Cerrado	2010	2020
A042	Brazlândia – DF	-48.131111	-15.599722	Cwb	Cerrado	2017	2020
A045	Águas Emendadas – DF	-47.625801	-15.596491	Aw	Cerrado	2008	2020
A046	Gama (Ponte Alta) – DF	-48.1375	-15.935278	Aw	Cerrado	2014	2020
A047	Paranoá (COOPA) -DF	-47.557417	-16.012222	Cwa	Cerrado	2017	2020
A056	Cristalina (Fazenda Santa Mônica) – GO	-47.625833	-16.399444	Aw	Cerrado	2018	2020
A702	Campo Grande – MS	-54.722615	-20.447195	Aw	Cerrado	2001	2020
A703	Ponta Porã – MS	-55.716389	-22.5525	Cfa	Cerrado	2001	2020
A704	Três Lagoas – MS	-51.712222	-20.783333	Aw	Mata Atlântica	2001	2020
A709	Ivinhema – MS	-53.822778	-22.300556	Aw	Mata Atlântica	2003	2020
A710	Paranaíba – MS	-51.181667	-19.695556	Aw	Cerrado	2006	2020
A717	Nhumirim – MS	-56.622778	-18.988611	Am	Pantanal	2006	2020

A719	Aquidauana – MS	-55.783889	-20.475556	Aw	Cerrado	2006	2020
A720	Coxim – MS	-54.736111	-18.512222	Aw	Cerrado	2006	2020
A721	Dourados – MS	-54.911389	-22.193889	Cfa	Mata Atlântica	2006	2020
A722	Miranda – MS	-56.431667	-20.395556	Am	Cerrado	2006	2020
A723	Porto Murtinho – MS	-57.886667	-21.705833	Af	Pantanal	2006	2020
A724	Corumbá – MS	-57.6375	-18.99667	Aw	Pantanal	2006	2020
A730	Chapadão do Sul – MS	-52.6025	-18.802222	Am	Cerrado	2006	2020
A731	Maracaju – MS	-55.1775	-21.609167	Am	Cerrado	2006	2020
A732	São Gabriel do Oeste – MS	-54.553056	-19.420278	Am	Cerrado	2006	2020
A742	Cassilândia – MS	-51.720833	-19.1225	Am	Cerrado	2008	2020
A743	Rio Brillhante – MS	-54.528108	-21.774944	Am	Mata Atlântica	2008	2020
A749	Juti – MS	-54.605556	-22.857222	Cfa	Mata Atlântica	2008	2020
A750	Amambai – MS	-55.329444	-23.0025	Cfa	Mata Atlântica	2008	2020
A751	Sete Quedas – MS	-55.024167	-23.966944	Cfa	Mata Atlântica	2008	2020
A752	Itaquiraí – MS	-54.181858	-23.449501	Cfa	Mata Atlântica	2008	2020
A754	Sidrolândia – MS	-54.971944	-20.981667	Am	Cerrado	2008	2020
A756	Água Clara – MS	-52.875833	-20.444444	Am	Cerrado	2010	2020
A757	Bela Vista – MS	-56.540833	-22.101667	Af	Cerrado	2011	2020
A758	Jardim – MS	-56.137778	-21.478611	Af	Cerrado	2011	2020
A759	Bataguassu – MS	-52.471389	-21.75	Aw	Cerrado	2013	2020
A760	Costa Rica – MS	-53.171389	-18.492778	Am	Cerrado	2012	2020
A761	Sonora – MS	-54.760556	-17.635278	Aw	Cerrado	2012	2020
A901	Cuiabá – MT	-56.062951	-15.559295	Aw	Cerrado	2002	2020
A902	Tangará da Serra – MT	-57.431667	-14.65	Aw	Amazônia	2002	2020
A903	São José do Rio Claro – MT	-56.677222	-13.453889	Aw	Cerrado	2003	2020
A904	Sorriso – MT	-55.722778	-12.555	Aw	Cerrado	2002	2020
A905	Campo Novo do Parecis – MT	-57.838611	-13.785833	Aw	Cerrado	2002	2020
A906	Guarantã do Norte – MT	-54.897778	-9.9525	Am	Amazônia	2002	2020
A907	Rondonópolis – MT	-54.580278	-16.4625	Aw	Cerrado	2003	2020
A908	Água Boa – MT	-52.211667	-14.016389	Aw	Cerrado	2006	2020
A909	Alto Araguaia – MT	-53.224444	-17.339444	Aw	Cerrado	2011	2020
A910	Apiacas – MT	-57.393611	-9.563333	Am	Amazônia	2006	2020
A911	Sapezal – MT	-58.763333	-13.303889	Am	Cerrado	2017	2020
A912	Campo Verde – MT	-55.135556	-15.531389	Aw	Cerrado	2006	2020
A913	Comodoro – MT	-59.7625	-13.708056	Am	Amazônia	2006	2020
A914	Juara – MT	-57.526667	-11.280278	Am	Amazônia	2006	2020
A915	Paranatinga – MT	-54.036111	-14.421389	Aw	Cerrado	2006	2020
A916	Querência – MT	-52.220833	-12.627222	Aw	Amazônia	2007	2020
A917	Sinop – MT	-55.566111	-11.982222	Am	Amazônia	2006	2020
A918	Confresa – MT	-51.571389	-10.639444	Aw	Amazônia	2008	2018
A919	Cotriguaçu – MT	-58.572222	-9.906389	Am	Amazônia	2007	2020
A920	Juína – MT	-58.774785	-11.375126	Am	Amazônia	2006	2020
A921	São Félix do Araguaia – MT	-50.727778	-11.618889	Aw	Cerrado	2007	2020
A922	Vila Bela da Santíssima Trindade – MT	-59.873056	-15.062778	Am	Amazônia	2006	2020
A923	Primavera do Leste – MT	-54.381111	-15.58	Aw	Cerrado	2017	2020
A924	Alta Floresta – MT	-56.179167	-10.077222	Am	Amazônia	2007	2020
A926	Carlinda – MT	-55.8275	-9.970556	Am	Amazônia	2008	2020

A927	Brasnorte (Novo Mundo) – MT	-58.231389	-12.521944	Am	Cerrado	2008	2020
A928	Nova Maringá – MT	-57.092222	-13.038611	Aw	Amazônia	2008	2020
A929	Nova Ubiratã – MT	-54.752222	-13.411111	Aw	Cerrado	2008	2020
A930	Gaúcha do Norte – MT	-53.2575	-13.184722	Am	Amazônia	2008	2020
A931	Santo Antônio do Leste – MT	-53.883611	-14.927778	Aw	Cerrado	2008	2020
A932	Guiratinga – MT	-53.766111	-16.341667	Aw	Cerrado	2008	2020
A933	Itiquira – MT	-54.501667	-17.175	Aw	Cerrado	2008	2020
A934	Alto Taquari – MT	-53.289444	-17.841111	Aw	Cerrado	2008	2020
A935	Porto Estrela – MT	-57.225833	-15.324722	Aw	Cerrado	2008	2020
A936	Salto do Céu – MT	-58.127222	-15.124722	Aw	Amazônia	2008	2020
A937	Pontes e Lacerda – MT	-59.346111	-15.234444	Aw	Amazônia	2008	2020
A941	Cáceres – MT	-57.693056	-16.074722	Aw	Pantanal	2012	2020
A942	São José do Xingu – MT	-52.3725	-10.484167	Am	Amazônia	2019	2020
A943	Serra Nova Dourada – MT	-51.426111	-11.987778	Aw	Cerrado	2019	2020
A944	Rosário Oeste – MT	-56.441944	-14.828889	Aw	Cerrado	2019	2020
S701	Angélica – MS	-53.763736	-22.148083	Aw	Mata Atlântica	2018	2020
S702	Aral Moreira – MS	-55.626	-22.955028	Cfa	Mata Atlântica	2018	2020
S703	Bandeirantes – MS	-54.368611	-19.945556	Am	Cerrado	2018	2020
S704	Bonito – MS	-56.450556	-21.246667	Am	Cerrado	2018	2020
S705	Brasilândia – MS	-52.068889	-21.298333	Aw	Cerrado	2018	2020
S706	Caarapó – MS	-54.819306	-22.657056	Cfa	Mata Atlântica	2018	2020
S707	Camapuã – MS	-54.03	-19.5875	Am	Cerrado	2018	2020
S708	Fátima do Sul – MS	-54.325833	-22.308611	Am	Mata Atlântica	2018	2020
S709	Iguatemi – MS	-54.570278	-23.644444	Cfa	Mata Atlântica	2018	2020
S710	Itaporã – MS	-54.798833	-22.092833	Am	Mata Atlântica	2018	2020
S711	Laguna Carapã – MS	-55.160333	-22.575389	Cfa	Mata Atlântica	2018	2020
S712	Nova Alvorada do Sul – MS	-54.341972	-21.450972	Am	Cerrado	2018	2020
S713	Nova Andradina – MS	-53.465833	-22.078611	Aw	Cerrado	2018	2020
S714	Pedro Gomes – MS	-54.548889	-18.072778	Aw	Cerrado	2018	2020
S715	Ribas do Rio Pardo – MS	-53.763028	-20.466694	Am	Cerrado	2018	2020
S716	Santa Rita do Pardo – MS	-52.820375	-21.305889	Aw	Cerrado	2018	2020
S717	Selvíria – MS	-51.430278	-20.351389	Aw	Cerrado	2018	2020

Produtos de Reanálise e Sensoriamento Remoto

Foram analisados quatro produtos de reanálise atmosférica (ERA5-Land, GLDAS, JRA-55 e NCEP-DOE Reanalysis 2) e um produto baseado em sensoriamento remoto (MERRA-2), cujas principais características estão resumidas na Tabela 2. Os dados desses produtos foram extraídos para as células correspondentes à localização de cada estação meteorológica, garantindo a comparação pontual com as medições de superfície.

Para os produtos ERA5-Land, JRA-55 e NCEP-DOE, a velocidade do vento foi calculada a partir dos componentes zonal (u) e meridional (v), aplicando a fórmula padrão de velocidade vetorial. O ERA5-Land oferece dados com resolução temporal horária e espacial de $0.25^\circ \times 0.25^\circ$, baseando-se em sistemas de assimilação 4D-Var de última geração e um grande volume de dados observacionais (Wilczak et al., 2024; Xu et al., 2022; Tarek et al., 2020).

Tabela 2 – Descrição dos produtos de velocidade do vento de reanálise e de sensoriamento remoto.

Tabela 2 – Descrição dos produtos de velocidade do vento de reanálise e de sensoriamento remoto.						
Produtos		Versão	Variáveis	Resolução temporal	Resolução espacial	Disponível em
Reanálises	ERA5-Land	ERA5-Land hourly data on pressure levels	u e v	Horária	0.25° x 0.25°	cds.climate.copernicus.eu
	GLDAS	GLDAS_NOAH025_3H v2.1	V	3 horas	0.25° x 0.25°	disc.gsfc.nasa.gov
	JRA-55	Parameters of isobaric analysis fields (anl_p125)	u e v	6 horas	0.5° x 0.625°	jra.kishou.go.jp
	NCEP/DOE	NCEP-DOE Reanalysis 2: Pressure Level	u e v	Diária	2.5° x 2.5°	psl.noaa.gov
Sensoriamento Remoto	MERRA-2	M2I1NXLFO 5.12.4	V	Horária	0.25° x 0.25°	disc.gsfc.nasa.gov

O GLDAS (Global Land Data Assimilation System) fornece estimativas quase em tempo real dos estados e fluxos da superfície terrestre com resolução de 0.25°, integrando múltiplas fontes de dados, como medições terrestres e satelitais, para modelagem do ciclo hidrológico (Rodell et al., 2004; McNally et al., 2017). O JRA-55 incorpora um esquema de assimilação variacional 4D e avanços em física atmosférica, apresentando resolução espacial de 0.5° x 0.625° (Kobayashi et al., 2015; Das e Roy, 2024). Já o NCEP-DOE Reanalysis 2 combina observações com modelos numéricos de previsão em um sistema de assimilação 3D-Var, com resolução de 2.5° x 2.5°, buscando corrigir deficiências conhecidas de sua versão anterior (Kanamitsu et al., 2002; Peng et al., 2019).

Por fim, o MERRA-2 (Modern-Era Retrospective analysis for Research and Applications, Version 2) é produzido pelo Goddard Earth Observing System (GEOS) da NASA, combinando dados de satélite com modelos numéricos via assimilação estatística (GSI) para fornecer campos globais com resolução espacial de 0.5° x 0.625° (Gelaro et al., 2017). Os dados desses produtos foram extraídos em conformidade com as coordenadas das estações e processados para as escalas temporais diária, mensal e anual.

Indicativos de performance

A avaliação da qualidade dos produtos foi realizada para as três escalas temporais (diária, mensal e anual), considerando apenas os períodos em que as estações apresentaram séries completas. As médias e intervalos de confiança de 95% foram calculados utilizando o método de reamostragem bootstrap com 1000 replicações, permitindo estimar a precisão das estatísticas.

O desempenho dos produtos foi quantificado por métricas estatísticas amplamente empregadas: coeficiente de correlação de Spearman (r), índice de concordância de Willmott (d), raiz do erro quadrático médio (RMSE), erro médio absoluto (MAE), índice de concordância de Lin (pc) e viés percentual (PBIAS). Essas métricas avaliam a relação entre as séries temporais, a concordância global, a magnitude dos erros e os desvios sistemáticos entre estimativas e observações.

Para sintetizar a comparação entre os modelos, foi calculada uma classificação abrangente (MR) baseada no ranqueamento das métricas individuais, conforme proposto por Jiang et al. (2015). Essa abordagem avalia a consistência de desempenho entre os produtos analisados, atribuindo valor máximo de MR igual a 1 para o modelo que apresenta melhor desempenho em todas as métricas. As definições formais das métricas e o cálculo do índice MR estão descritos na Tabela 3.

Tabela 3 – Métricas estatísticas para validar os produtos de reanálise e de sensoriamento remoto.

Testes Estatísticos	Equação	Valores de referência
Spearman Correlation Coefficient (r)	$r = 1 - \frac{6 \sum_i^n d_i^2}{n^3 - n} \quad (1)$	$r = 1 \text{ or } -1$
Willmott's Concordance Index (d)	$d = 1 - \frac{\sum (P_i - O_i)^2}{\sum (P_i - O + O_i - O)^2} \quad (2)$	$d = 1$
Root Mean Squared Error (RMSE)	$RMSE = \sqrt{\frac{\sum (P_i - O_i)^2}{n}} \quad (3)$	$RMSE = 0$
Mean Absolute Error (MAE)	$MAE = \frac{\sum_i^n P_i - O_i}{n} \quad (4)$	$MAE = 0$
Lin's Concordance (ρ_c)	$\rho_c = \frac{2\rho\sigma_x\sigma_y}{2\sigma_x\sigma_y + (\sigma_x - \sigma_y)^2 + (\mu_x - \mu_y)^2} \quad (5)$	$\rho_c = 1 \text{ or } -1$
Percent Bias (PBIAS)	$PBIAS = \frac{\sum (P_i - O_i)^2}{\sum O_i} \times 100 \quad (6)$	$PBIAS = 0$

em que d_i representa a diferença entre os valores de cada par de observações e n denota o tamanho da amostra. O_i é o valor estimado da variável, com O representando o numerador do número de observações variando de 1 a n (dias, meses ou anos). O_i é o valor medido da variável, O é a média da variável medida. ρ é o coeficiente de correlação de Pearson, σ_x e σ_y correspondem às variâncias do primeiro e segundo conjuntos de medições, e μ_x e μ_y são as médias dos dois conjuntos.

$$M_R = 1 - \frac{1}{n \times m} \sum_{i=1}^n (Rank_{i_r} + Rank_{i_d} + Rank_{i_{RMSE}} + Rank_{i_{MAE}} + Rank_{i_{Lin}} + Rank_{i_{PBIAS}}) \quad (7)$$

em que n é o número total de índices, m é o número de modelos e o $Rank$ indica a ordem do modelo reduzido em cada índice em uma determinada métrica de desempenho. Portanto, o valor máximo de M_R é 1, indicando que o modelo é o melhor em todos os índices e métricas (Jiang et al. 2015).

Resultados

Observou-se discrepância significativa entre as estimativas de velocidade do vento dos diferentes produtos de reanálise e sensoriamento remoto e as medições das estações meteorológicas automáticas, especialmente em escala diária (Figura 2A). Em valores médios diários, o ERA5 ($1,87 \pm 0,02$ m/s) e o GLDAS ($2,01 \pm 0,02$ m/s) apresentaram estimativas ligeiramente superiores às observações, enquanto o MERRA-2 ($4,42 \pm 0,05$ m/s) superestimou substancialmente a velocidade do vento, com viés positivo de 143,8%. Esses resultados indicam que, apesar de ERA5 e GLDAS

manterem valores mais próximos das medições, há uma tendência geral de superestimação nas escalas mais curtas, especialmente pronunciada no MERRA-2.

Em escala mensal (Figura 2B), as estimativas do ERA5 ($1,88 \pm 0,05$ m/s) e do GLDAS ($2,01 \pm 0,06$ m/s) não apresentaram diferenças estatisticamente significativas em relação às observações, sugerindo bom desempenho para análises mensais. Por outro lado, o NCEP/DOE ($2,68 \pm 0,09$ m/s) e o MERRA-2 ($4,43 \pm 0,12$ m/s) mantiveram uma tendência sistemática de superestimação, com viés percentual de 57,4% e 143,3%, respectivamente, o que evidencia limitações na captura das variações mensais desses modelos.

Na escala anual (Figura 2C), ERA5, GLDAS e JRA-55 mostraram concordância satisfatória com as observações, sem diferenças médias relevantes, enquanto NCEP/DOE (PBIAS: 56,1%) e MERRA-2 (PBIAS: 140%) continuaram a superestimar consideravelmente a velocidade do vento. Esses padrões sugerem que os produtos com maior resolução espacial e técnicas de assimilação mais avançadas tendem a representar melhor a variabilidade interanual.

Ao se analisar os resultados por bioma, também se observaram diferenças importantes. Na

Amazônia, em escala diária, todos os produtos superestimaram a velocidade do vento em relação às medições, com maiores desvios para NCEP/DOE e MERRA-2 (44,4% e 50%, respectivamente), enquanto ERA5 e GLDAS apresentaram discrepâncias mais reduzidas (8,8% e 10%). Em escalas mensal e anual, porém, ERA5,

GLDAS e JRA-55 apresentaram melhor ajuste às observações, evidenciando que a variabilidade interanual na Amazônia é melhor capturada por esses produtos.




Figura 2. Médias e intervalos de confiança (95%) da velocidade do vento em escalas diária, mensal e anual, comparando medições de estações automáticas do INMET com estimativas dos produtos ERA5, GLDAS, JRA-55, MERRA-2 e NCEP/DOE, nos biomas do Centro-Oeste do Brasil (2000–2020).

No Cerrado, o ERA5 destacou-se por manter estimativas próximas às observações em todas as escalas temporais, enquanto NCEP/DOE e MERRA-2 persistiram em superestimar a velocidade do vento. GLDAS também apresentou desempenho consistente, com menor viés em escala diária (13,0%).

Para o Pantanal, todas as estimativas dos produtos de reanálise diferiram significativamente

das observações, independentemente da escala. O MERRA-2 e o NCEP/DOE exibiram as maiores superestimativas, enquanto o GLDAS teve o menor desvio em escala anual (28,0%), embora ainda alto para aplicações precisas.

Na Mata Atlântica, a maioria dos produtos também superestimou os valores observados, sobretudo em escala diária. O MERRA-2 apresentou os maiores desvios em todas as escalas,

seguido por NCEP/DOE, ao passo que ERA5 e GLDAS mantiveram melhor ajuste em escalas mensal e anual.

A classificação abrangente dos modelos (MR), ilustrada na Figura 3, reforça essas diferenças de desempenho. Em todas as escalas temporais, o ERA5 apresentou os maiores valores de MR, indicando maior consistência em relação às observações (0,87 diário; 0,70 mensal; 0,73 anual). O GLDAS apresentou desempenho intermediário (MR diário de 0,77), superando JRA-55, NCEP/DOE e, sobretudo, MERRA-2, que obteve os menores valores de MR em todas as escalas (0,40 diário, por exemplo).

Nos diferentes biomas, essa tendência se manteve. Na Amazônia, ERA5 e GLDAS

demonstraram maior concordância com as medições, especialmente em escalas mensal e anual. No Cerrado, ambos os produtos mantiveram desempenho robusto em todas as escalas, enquanto NCEP/DOE e MERRA-2 apresentaram resultados menos confiáveis. No Pantanal, o GLDAS se destacou, ainda que com viés considerável, enquanto na Mata Atlântica o ERA5 foi o produto com melhor classificação geral. Esses resultados evidenciam a necessidade de uma seleção criteriosa dos produtos de reanálise e sensoriamento remoto conforme o bioma, a escala temporal e a aplicação pretendida.




Figura 3. Índice de classificação geral (MR) para os produtos de reanálise e sensoriamento remoto, avaliando o desempenho na estimativa de velocidade do vento em escalas diária, mensal e anual nos biomas do Centro-Oeste do Brasil (2000–2020). Valores mais altos indicam melhor concordância com as observações.

Discussão

A escassez de dados observacionais de vento no Centro-Oeste do Brasil representa uma limitação significativa para o avanço das pesquisas climáticas regionais, especialmente diante da complexidade da dinâmica do vento em diferentes escalas temporais. Embora os produtos de reanálise e os dados de sensoriamento remoto ofereçam alternativas valiosas para suprir essas lacunas, persiste o desafio de reconciliar as discrepâncias entre essas fontes e as medições diretas em superfície (Siefert et al., 2021).

Entre os produtos avaliados, o ERA5 se destaca por empregar uma metodologia avançada de assimilação variacional de dados 4D-Var, que integra observações ao longo do tempo e melhora a representação das condições atmosféricas (Xu et al., 2022). Sua alta resolução espacial e temporal, combinada com esquemas físicos aprimorados, como a parametrização da camada limite e a interação atmosfera-superfície, resulta em estimativas mais confiáveis da velocidade do vento. A incorporação eficiente de dados satelitais e o processo contínuo de atualização reforçam a robustez do ERA5 como fonte de dados (Hersbach et al., 2020).

O JRA-55, por outro lado, apresentou desempenho mais variável, com tendência à superestimativa em escalas diárias em determinados locais. Essas diferenças podem ser atribuídas a limitações em seus esquemas de parametrização da camada limite e às estratégias de assimilação de dados empregadas (Kobayashi et al., 2015). A comparação geral entre os produtos de reanálise evidencia a superioridade do ERA5 e do GLDAS em relação ao JRA-55, MERRA-2 e NCEP/DOE. A resolução espacial mais grosseira destes últimos limita sua capacidade de representar detalhes da dinâmica atmosférica, especialmente em regiões com topografia complexa como o Centro-Oeste brasileiro. Adicionalmente, a qualidade e quantidade dos dados assimilados e a complexidade dos esquemas de parametrização influenciam diretamente o desempenho dos modelos (Siefert et al., 2021; Ramon et al., 2019).

As diferenças nos métodos de parametrização vertical também impactam as estimativas de velocidade do vento. O ERA5 utiliza o esquema Monin-Obukhov modificado, que considera as características de superfície e a estabilidade atmosférica de forma mais detalhada. Em contraste, o MERRA-2 adota o esquema de Helfand e Schubert, enquanto o JRA-55 emprega

uma abordagem mais simplificada baseada na suposição de estabilidade neutra. Essas distinções metodológicas podem explicar as discrepâncias observadas entre os produtos (Fan et al., 2021).

Outro fator limitante importante é a própria rede de estações meteorológicas na região Centro-Oeste, cuja baixa densidade espacial reduz a qualidade e a quantidade de dados disponíveis para validação e desenvolvimento de modelos climáticos. Embora os produtos de reanálise ofereçam soluções relevantes, a dependência exclusiva dessas fontes pode comprometer a precisão das estimativas, sobretudo em áreas com características geográficas complexas. A carência de dados observacionais em superfície dificulta a configuração adequada dos modelos e a compreensão detalhada dos padrões climáticos locais (Junior et al., 2021).

A comparação entre medições observadas e estimativas dos produtos de reanálise, tanto na Amazônia quanto no Centro-Oeste em geral, revelou que nenhum dos modelos avaliados conseguiu representar de forma totalmente precisa a variabilidade espacial e temporal da velocidade do vento. A Amazônia, por sua densa cobertura florestal e alta umidade, impõe desafios particulares para a simulação dessa variável, enquanto o Centro-Oeste, com sua topografia heterogênea, também complica a performance dos modelos. Esses resultados estão em consonância com estudos anteriores que evidenciam as limitações das reanálises para representar com fidelidade a velocidade do vento superficial em regiões com geografia complexa e condições microclimáticas específicas (Zhang et al., 2019; Rose e Apt, 2016; Siefert et al., 2022).

Um exemplo emblemático dessas dificuldades é a Amazônia, cuja rugosidade superficial elevada e os gradientes de pressão moderados contribuem para baixas velocidades médias de vento, tanto sazonalmente quanto anualmente. Embora haja correlação geral entre as medições observadas e as estimativas dos modelos, a variabilidade espacial e temporal não é capturada de forma satisfatória, refletindo as limitações na representação dos processos físicos subjacentes (Siefert et al., 2022).

Por fim, as incertezas associadas ao uso de dados de velocidade do vento provenientes de reanálises podem ser mitigadas com o uso de fatores de correção. Estratégias baseadas em dados de estações meteorológicas ou modelos estatísticos têm demonstrado potencial para melhorar a qualidade das estimativas e, consequentemente, a confiabilidade dos resultados em aplicações que

vão da meteorologia operacional à modelagem climática e ao planejamento energético (Siefert et al., 2022).

Conclusão

Este estudo avaliou a qualidade e a confiabilidade de cinco produtos de reanálise e sensoriamento remoto na estimativa da velocidade do vento no Centro-Oeste do Brasil, comparando suas estimativas com dados observacionais de 120 estações meteorológicas automáticas entre 2000 e 2020. Os resultados demonstraram que o desempenho dos produtos varia significativamente em função da escala temporal e das características dos diferentes biomas.

De modo geral, o ERA5 apresentou o melhor desempenho, com elevada concordância com os dados observados em todas as escalas e biomas, resultado atribuído à sua alta resolução espacial e temporal e ao uso de técnicas avançadas de assimilação de dados. O GLDAS também apresentou estimativas consistentes em várias situações, especialmente em biomas como o Cerrado. Em contraste, os produtos NCEP/DOE e MERRA-2 apresentaram superestimação sistemática da velocidade do vento, com viés mais acentuado em escalas diárias e em regiões de vegetação densa ou topografia complexa, como a Amazônia e o Pantanal.

Esses achados ressaltam a importância de uma seleção criteriosa dos produtos de reanálise e sensoriamento remoto para aplicações regionais. A escolha inadequada de dados pode introduzir incertezas significativas em estudos climáticos, hidrológicos e de planejamento energético, especialmente em regiões com cobertura observacional limitada. Recomenda-se, portanto, a adoção do ERA5 como fonte preferencial para estimativas de velocidade do vento no Centro-Oeste brasileiro, particularmente para aplicações em planejamento de energia eólica e modelagem climática regional. Contudo, os resultados também indicam a necessidade de validações locais e, quando possível, ajustes estatísticos ou correções baseadas em medições de superfície para reduzir incertezas residuais, especialmente em biomas com condições atmosféricas complexas.

Ao fornecer uma avaliação detalhada do desempenho desses produtos em diferentes escalas e biomas, este trabalho contribui para apoiar decisões mais informadas sobre o uso de dados de reanálise e sensoriamento remoto em estudos científicos e aplicações práticas na região,

fortalecendo as bases para o desenvolvimento sustentável e a gestão ambiental no Centro-Oeste do Brasil.

Referências

- Baatz, R., Hendricks Franssen, H.J., Euskirchen, E., Sihi, D., Dietze, M., Ciavatta, S., Fennel, K., Beck, H., de Lannoy, G., Pauwels, V.R.N., Raiho, A., Montzka, C., Williams, M., Mishra, U., Poppe, C., Zacharias, S., Lausch, A., Samaniego, L., Van Looy, K., Bogen, H., Adamescu, M., Mirtl, M., Fox, A., Goergen, K., Naz, B. S., Zeng, Y., Vereecken, H., 2021. Reanalysis in Earth System Science: Toward Terrestrial Ecosystem Reanalysis. *Reviews of Geophysics* 59, e2020RG000715. <https://doi.org/10.1029/2020RG000715>
- Bhuiyan, M.A.E., Nikolopoulos, E.I., Anagnostou, E.N., 2019. Machine Learning–Based Blending of Satellite and Reanalysis Precipitation Datasets: A Multiregional Tropical Complex Terrain Evaluation. *Journal of Hydrometeorology* 20, 2147–2161. <https://doi.org/10.1175/JHM-D-19-0073.1>
- Das, A., Roy, S.B. 2024. JRA55 is the best reanalysis representing observed near-surface wind speeds over India. *Atmospheric Research* 297, 107111. <https://doi.org/10.1016/j.atmosres.2023.107111>
- de Aquino Ferreira, S.C., Cyrino Oliveira, F.L., Maçaira, P.M., 2022. Validation of the representativeness of wind speed time series obtained from reanalysis data for Brazilian territory. *Energy* 258, 124746. <https://doi.org/10.1016/j.energy.2022.124746>
- de Souza, A., de Medeiros, E.S., de Olinda, R.A., Oliveira-Júnior, J.F., Pobocikova, I., Abreu, M.C., Cavazzana, G.H., Pansera, W.A. 2024. Trends and Hydroclimatic Variability in Brazil. *Earth Systems and Environment*. <https://doi.org/10.1007/s41748-024-00434-9>
- Fan, W., Liu, Y., Chappell, A., Dong, L., Xu, R., Ekström, M., Fu, T.-M., Zeng, Z., 2021. Evaluation of Global Reanalysis Land Surface Wind Speed Trends to Support Wind Energy Development Using In Situ Observations. *Journal of Applied Meteorology and Climatology* 60, 33–50. <https://doi.org/10.1175/JAMC-D-20-0037.1>
- Gelaro, R., Mccarty, W., Suárez, M.J., Todling, R., Molod, A., Takacs, L., Randles, C.A., Darmenov, A., Bosilovich, M.G., Reichle, R., Wargan, K., Coy, L., Cullather, R., Draper, C.,

- Akella, S., Buchard, V., Conaty, A., Silva, A.M. da, Gu, W., Kim, G.-K., Koster, R., Lucchesi, R., Merkova, D., Nielsen, J.E., Partyka, G., Pawson, S., Putman, W., Rienecker, M., Schubert, S.D., Sienkiewicz, M., Zhao, B., 2017. The Modern-Era Retrospective Analysis for Research and Applications, Version 2 (MERRA-2). *Journal of Climate* 30, 5419–5454. <https://doi.org/10.1175/JCLI-D-16-0758.1>
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., ... & Thépaut, J. N. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146(730), 1999–2049.
- Jiang, Z., Li, W., Xu, J., Li, L., 2015. Extreme Precipitation Indices over China in CMIP5 Models. Part I: Model Evaluation. *Journal of Climate* 28, 8603–8619. <https://doi.org/10.1175/JCLI-D-15-0099.1>
- Junior, A.L.P., Biudes, M.S., Machado, N.G., Vourlitis, G.L., Geli, H.M.E., Santos, L.O.F.S., Querino, C.A.S., Ivo, I.O., Neto, N.L., 2021. Assessment of Remote Sensing and Re-Analysis Estimates of Regional Precipitation over Mato Grosso, Brazil. *Water* 13, 333. <https://doi.org/10.3390/w13030333>
- Kanamitsu, M., Ebisuzaki, W., Woollen, J., Yang, S.-K., Hnilo, J.J., Fiorino, M., Potter, G.L., 2002. NCEP–DOE AMIP-II Reanalysis (R-2). *Bulletin of the American Meteorological Society* 83, 1631–1644. <https://doi.org/10.1175/BAMS-83-11-1631>
- Kobayashi, S., Ota, Y., Harada, Y., Ebata, A., Moriya, M., Onoda, H., ... & Takahashi, K. (2015). The JRA-55 reanalysis: General specifications and basic characteristics. *Journal of the Meteorological Society of Japan. Ser. II*, 93(1), 5–48.
- Mariano, E.B., Cavalcanti, E.P., Beserra, E.A., 2017. Análise Comparativa da Velocidade do Vento Simulado Pelo BRAMS com Dados Observados e de Reanálises. *Rev. bras. meteorol.* 32, 269–276. <https://doi.org/10.1590/0102-778632220160128>
- Ramon, J., Lledó, L., Torralba, V., Soret, A., Doblas-Reyes, F.J., 2019. What global reanalysis best represents near-surface winds? *Quarterly Journal of the Royal Meteorological Society* 145, 3236–3251. <https://doi.org/10.1002/qj.3616>
- Rose, S., Apt, J., 2016. Quantifying sources of uncertainty in reanalysis derived wind speed. *Renewable Energy* 94, 157–165. <https://doi.org/10.1016/j.renene.2016.03.028>
- Siefert, C.A.C., Dombrowski Netto, N., Marangon, F.H.S., Schultz, G.B., Silva, L.M. DOS R., Fontenelle, T.H., Santos, I. dos, 2022. Avaliação de Séries de Velocidade do Vento de Produtos de Reanálises Climáticas para o Brasil. *Rev. bras. meteorol.* 36, 689–701. <https://doi.org/10.1590/0102-7786360026>
- Teixeira de Aguiar, J., Lobo, M., 2020. Reliability and discrepancies of rainfall and temperatures from remote sensing and Brazilian ground weather stations. *Remote Sensing Applications: Society and Environment* 18, 100301. <https://doi.org/10.1016/j.rsase.2020.100301>
- Vilpoux, O.F., Gonzaga, J.F., Pereira, M.W.G., 2021. Agrarian reform in the Brazilian Midwest: Difficulties of modernization via conventional or organic production systems. *Land Use Policy* 103.
- Xavier, A.C., King, C.W., Scanlon, B.R., 2016. Daily gridded meteorological variables in Brazil (1980–2013). *International Journal of Climatology* 36, 2644–2659. <https://doi.org/10.1002/joc.4518>
- Wilczak, J.M., Akish, E., Capotondi, A., Compo, G.P. 2024. Evaluation and Bias Correction of the ERA5 Reanalysis over the United States for Wind and Solar Energy Applications. *Energies* 17(7), 1667. <https://doi.org/10.3390/en17071667>
- Zhang, R., Zhang, S., Luo, J., Han, Y., Zhang, J., 2019. Analysis of near-surface wind speed change in China during 1958–2015. *Theor Appl Climatol* 137, 2785–2801. <https://doi.org/10.1007/s00704-019-02769-0>