

**UNIVERSIDADE FEDERAL DE MATO GROSSO
INSTITUTO FÍSICA
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA AMBIENTAL**

**VALIDAÇÃO DE ELEMENTOS CLIMÁTICOS ESTIMADOS POR
SENSORIAMENTO REMOTO E REANÁLISES NA REGIÃO CENTRO-OESTE
DO BRASIL**

JULIANA BARBOSA DA SILVA LOTUFO

PROF^a. DR^a. NADJA GOMES MACHADO

**Cuiabá - MT
Dezembro/2023**

**UNIVERSIDADE FEDERAL DE MATO GROSSO
INSTITUTO FÍSICA
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA AMBIENTAL**

**VALIDAÇÃO DE ELEMENTOS CLIMÁTICOS ESTIMADOS POR
SENSORIAMENTO REMOTO E REANÁLISES NA REGIÃO CENTRO-OESTE
DO BRASIL**

JULIANA BARBOSA DA SILVA LOTUFO

*Tese apresentada ao Programa de Pós-
Graduação em Física Ambiental da
Universidade Federal de Mato Grosso,
como parte dos requisitos para obtenção
do título de Doutora em Física Ambiental.*

PROF^a. DR^a. NADJA GOMES MACHADO
Orientadora

**Cuiabá - MT
Dezembro/2023**

Dados Internacionais de Catalogação na Fonte.

L884v Lotufo, Juliana.

Validação de elementos climáticos estimados por sensoriamento remoto e reanálises na região Centro-Oeste do Brasil [recurso eletrônico] / Juliana Loturo. -- Dados eletrônicos (1 arquivo : 132 f., il. color., pdf). -- 2023.

Orientadora: Nadja Gomes Machado.

Tese (doutorado) - Universidade Federal de Mato Grosso, Instituto de Física, Programa de Pós-Graduação em Física Ambiental, Cuiabá, 2023.

Modo de acesso: World Wide Web: <https://ri.ufmt.br>.

Inclui bibliografia.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

Permitida a reprodução parcial ou total, desde que citada a fonte.



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE MATO GROSSO
PRÓ-REITORIA DE ENSINO DE PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA AMBIENTAL

FOLHA DE APROVAÇÃO

TÍTULO: VALIDAÇÃO DE ELEMENTOS CLIMÁTICOS ESTIMADOS POR SENSORIAMENTO REMOTO E REANÁLISES NA REGIÃO CENTRO-OESTE DO BRASIL

AUTORA: DOUTORANDA JULIANA BARBOSA DA SILVA LOTUFO

Tese defendida e aprovada em **11 de DEZEMBRO** de **2023**.

COMPOSIÇÃO DA BANCA EXAMINADORA

- 1. Profa. Dra. NADJA GOMES MACHADO** (Presidente Banca / **ORIENTADORA**)
INSTITUIÇÃO: INSTITUTO FEDERAL DE MATO GROSSO
- 2. Prof. Dr. MARCELO SACARDI BIUDES** (Membro Interno)
INSTITUIÇÃO: UNIVERSIDADE FEDERAL DE MATO GROSSO
- 3. Prof. Dr. LEONE FRANCISCO AMORIM CURADO** (Membro Interno)
INSTITUIÇÃO: UNIVERSIDADE FEDERAL DE MATO GROSSO
- 4. Prof. Dr. CARLOS ALEXANDRE SANTOS QUERINO** (Membro Externo)
INSTITUIÇÃO: UNIVERSIDADE FEDERAL DO AMAZONAS
- 5. Profa. Dra. JULIANE KAYSE ALBUQUERQUE DA SILVA QUERINO** (Membro Externo)
INSTITUIÇÃO: UNIVERSIDADE FEDERAL DO AMAZONAS

CUIABÁ, 11/12/2023.



Documento assinado eletronicamente por **MARCELO SACARDI BIUDES**, **Coordenador(a) de Programas de Pós-Graduação em Física Ambiental - IF/UFMT**, em 14/02/2024, às 12:00, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **LEONE FRANCISCO AMORIM CURADO**, **Docente da Universidade Federal de Mato Grosso**, em 14/02/2024, às 15:30, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Carlos Alexandre Santos Querino**, **Usuário Externo**, em 14/02/2024, às 17:48, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Juliane Kayse Albuquerque da Silva Querino**, **Usuário Externo**, em 16/02/2024, às 10:55, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **NADJA GOMES MACHADO**, **Usuário Externo**, em 16/02/2024, às 12:24, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufmt.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **6455265** e o código CRC **64F3C21E**.

DEDICATÓRIA

A Deus pela vida e oportunidade, e aos queridos familiares e amigos, pelo amor, apoio e compreensão nas horas difíceis. Em especial, à minha filha, Júlia Lotufo.

AGRADECIMENTOS

- Agradeço a Deus por me sustentar até aqui;
- Aos meus familiares, principalmente aos meus pais, à minha filha e meus irmãos, por todo amor, ajuda e motivação;
- À minha orientadora e Profa. Dra. Nadja Gomes Machado, pela amizade, compreensão e paciência. Foi um privilégio ser orientada por uma excelente pesquisadora, por quem tenho muita admiração. Agradeço por compartilhar do seu conhecimento e ter sido compreensível e acessível durante todo o andamento do doutorado;
- Ao Professor Dr. Marcelo Sacardi Biudes, pela amizade, pela paciência, compreensão e conhecimento compartilhado;
- Aos docentes do Programa de Pós-graduação em Física Ambiental (PPGFA) pelos ensinamentos e contribuições;
- A todos os técnicos do Programa de Pós-Graduação em Física Ambiental (PPGFA);
- Aos membros do Grupo de Pesquisa em Interação Biosfera Atmosfera (GPIBA);
- Aos meus amigos Altemar Lopes, Fernando e Nivalda, pela parceria, apoio e amizade sempre;
- Agradeço em especial ao Névio Lotufo Neto e Luiz Octávio, que contribuíram significativamente com o desenvolvimento da minha tese;
- À Universidade Federal de Mato Grosso (UFMT) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de doutorado;
- À banca examinadora desta tese.

SUMÁRIO

LISTA DE FIGURAS	XXXI
LISTA DE TABELAS	XXXIV
LISTA DE SIGLAS E ABREVIATURAS	XXXVII
RESUMO	XXXIX
ABSTRACT	XLI
1. INTRODUÇÃO.....	1
2. FUNDAMENTAÇÃO TEÓRICA	4
3. ARTIGOS.....	17
3.1 CAPÍTULO 1 – VALIDAÇÃO DE PRODUTOS DE SATÉLITE E REANÁLISE DE VELOCIDADE DO VENTO NO CENTRO-OESTE BRASILEIRO	17
3.2 CAPÍTULO 2 – VALIDAÇÃO DE PRODUTOS DE PRECIPITAÇÃO DE SENSORIAMENTO REMOTO E REANÁLISES SOBRE O CENTRO-OESTE DO BRASIL	
38	
3.3 CAPÍTULO 3 – VALIDAÇÃO DE REANÁLISES DE TEMPERATURA DO AR, UMIDADE RELATIVA DO AR E DÉFICIT DE PRESSÃO DE VAPOR PARA O CENTRO-OESTE BRASILEIRO	62
4. CONSIDERAÇÕES FINAIS DA TESE.....	105
5. REFERÊNCIAS DA INTRODUÇÃO GERAL E FUNDAMENTAÇÃO TEÓRICA..	106
6. ANEXO DA TESE.....	110

LISTA DE FIGURAS

FIGURA 1 Estações meteorológicas da região Centro-Oeste do Brasil (A), biomas (B), clima (C).	21
FIGURA 2 Valores médios de velocidade do vento \pm intervalo de confiança (IC) para medições diárias, mensais e anuais, para os biomas Amazônia, Cerrado, Pantanal e Mata Atlântica, medidas por estações meteorológicas automáticas do INMET e estimadas por produtos ERA-5, GLDAS, JRA-55, MERRA-2 e NCEP/DOE na região Centro Oeste do Brasil, de 2000 a 2020.	26
FIGURA 3 Classificação abrangente de modelos (MR) de produtos de reanálise e sensoriamento remoto usados para validar estimativas de velocidade do vento em escalas diária, mensal e anual e para biomas na região Centro-Oeste brasileira, de 2000 a 2020.	28
FIGURA 4 - Distribuição espacial das estações meteorológicas automáticas de superfície na região Centro-Oeste do Brasil.	41
FIGURA 5 Valores médios de precipitação \pm intervalo de confiança (IC) correspondente a escalas diária (mm dia^{-1}), mensal (mm mês^{-1}) e anual (mm ano^{-1}) medido por estações meteorológicas automáticas do INMET e estimado por produtos GLDAS, GPCP, GPM, MERRA, TRMM, CHIRPS, CPC, ERA5-Land e a média multimodelo Ensemble para os biomas da região Centro Oeste, Brasil.	47
FIGURA 6 Classificação das estimativas de precipitação pelos produtos CHIRPS, CPC, GLDAS, GPCP, GPM, MERRA, TRMM e a média multi-modelo Ensemble utilizando métricas de desempenho (r, d, RMSE, MAE, PBIAS e LIN) correspondente a dados diário (mm dia^{-1}), mensal (mm mês^{-1}) e anual (mm ano^{-1}) (A) e aos biomas Amazônia (B), Cerrado (C), Pantanal (D) e Mata Atlântica (E) da região Centro Oeste, Brasil.	49
FIGURA 7 Distribuição espacial das estações meteorológicas automáticas de superfície (A), biomas (B), classificação climática (C) e altitude (D) do Centro-Oeste do Brasil.	65
FIGURA 8 Representação espacial das localizações das estações meteorológicas e a resolução da grade (como mostrado na Tabela 8) dos produtos de temperatura do ar, umidade relativa do ar e deficit de pressão de vapor.	69
FIGURA 9 Valores médios de temperatura do ar máxima \pm intervalo de confiança (IC) diário (A), mensal(B) e anual(C) medido por estações meteorológicas automáticas do INMET e estimado por produtos ERA5-LAND, GLDAS, JRA55, MERRA2, NCEP/DOE, CPC e a média multi-modelo Ensemble na região Centro Oeste, Brasil. Para (A), foi	

calculada a média dos valores diários para todo o período de estudo, enquanto para (B), foi calculada a média dos valores mensais para todos os meses durante o período de estudo, e os valores anuais em (C) foram os valores anuais calculados para todos anos durante o período de estudo.	73
FIGURA 10 Classificação das estimativas de temperatura do ar máxima ($T_{ar_{max}}$) pelos produtos CHIRPS, CPC, GLDAS, GPCP, GPM, MERRA, TRMM, ENS e a média multi-modelo Ensemble utilizando métricas de desempenho (r, d, RMSE, MAE, PBIAS e LIN) correspondente a dados diário, mensal e anual (A) e aos biomas Amazônia (B), Cerrado (C), Mata Atlântica (D) e Pantanal (E), região Centro Oeste, Brasil.....	75
FIGURA 11 Valores médios de temperatura do ar média \pm intervalo de confiança (IC) diário (A), mensal(B) e anual(C) medido por estações meteorológicas automáticas do INMET e estimado por produtos ERA5-LAND, GLDAS, JRA55, MERRA2, NCEP/DOE, CPC e a média multi-modelo Ensemble na região Centro Oeste, Brasil. Para (A), foi calculada a média dos valores diários para todo o período de estudo, enquanto para (B), foi calculada a média dos valores mensais para todos os meses durante o período de estudo, e os valores anuais em (C) foram os valores anuais calculados para todos anos durante o período de estudo.	76
FIGURA 12 Classificação das estimativas de temperatura do ar média (T_{armed}) pelos produtos CHIRPS, CPC, GLDAS, GPCP, GPM, MERRA, TRMM, ENS e a média multi-modelo Ensemble utilizando métricas de desempenho (r, d, RMSE, MAE, PBIAS e LIN) correspondente a dados diário, mensal e anual (A) e aos biomas Amazônia (B), Cerrado (C), Mata Atlântica (D) e Pantanal (E), região Centro Oeste, Brasil.....	78
FIGURA 13 Valores médios de temperatura do ar mínima \pm intervalo de confiança (IC) diário (A), mensal(B) e anual(C) medido por estações meteorológicas automáticas do INMET e estimado por produtos ERA5-LAND, GLDAS, JRA55, MERRA2, NCEP/DOE, CPC e a média multi-modelo Ensemble na região Centro Oeste, Brasil. Para (A), foi calculada a média dos valores diários para todo o período de estudo, enquanto para (B), foi calculada a média dos valores mensais para todos os meses durante o período de estudo, e os valores anuais em (C) foram os valores anuais calculados para todos anos durante o período de estudo.	79
FIGURA 14 Classificação das estimativas de temperatura do ar mínima ($T_{ar_{min}}$) pelos produtos CHIRPS, CPC, GLDAS, GPCP, GPM, MERRA, TRMM, ENS e a média multi-modelo Ensemble utilizando métricas de desempenho (r, d, RMSE, MAE, PBIAS e LIN)	

correspondente a dados diário, mensal e anual (A) e aos biomas Amazônia (B), Cerrado (C), e Pantanal (D) e Mata Atlântica (E), região Centro Oeste, Brasil. 81

FIGURA 15 Classificação das estimativas de umidade relativa do ar (*UR*) pelos produtos ERA5-Land, GLDAS, JRA55 e NCEP/DOE utilizando métricas de desempenho (r, d, RMSE, MAE, PBIAS e LIN) correspondentes a dados diário, mensal, anual e aos biomas Amazônia, Cerrado, Pantanal e Mata Atlântica, região Centro Oeste, Brasil. .82

FIGURA 16 Classificação das estimativas de déficit de pressão de vapor (*DPV*) pelos produtos ERA5-Land, GLDAS, JRA55 e NCEP/DOE utilizando métricas de desempenho (r, d, RMSE, MAE, PBIAS e LIN) correspondentes a dados diário, mensal, anual e aos biomas Amazônia, Cerrado, Pantanal e Mata Atlântica, região Centro Oeste, Brasil. .83

LISTA DE TABELAS

TABELA 1 Descrição do conjunto de dados de velocidade do vento de produtos de reanálise e sensoriamento remoto.	22
TABELA 2 Métricas estatísticas para validar os produtos.....	23
TABELA 3 Análise de concordância de produtos de reanálise e sensoriamento remoto utilizados para validar estimativas de velocidade do vento (V) em escalas diária, mensal e anual na região Centro-Oeste brasileira, de 2000 a 2020.....	35
TABELA 4 Análise de concordância de produtos de reanálise e sensoriamento remoto utilizados para validar estimativas de velocidade do vento (V) para biomas da região Centro-Oeste brasileira, de 2000 a 2020.....	35
TABELA 5 Versão, resolução temporal e espacial dos produtos de sensoriamento remoto e reanálises utilizados para validar as estimativas de Precipitação (Ppt) para a região Centro-Oeste do Brasil.....	42
TABELA 6 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da precipitação (Ppt) nas escalas diária, mensal e anual pelos produtos CHIRPS, CPC, GLDAS, GPCP, GPM, MERRA-2, TRMM e ensemble para a região Centro-Oeste do Brasil.....	58
TABELA 7 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da precipitação (Ppt) para os biomas da região Centro-Oeste do Brasil.....	59
TABELA 8 Versão, resolução temporal e espacial dos produtos de reanálises utilizados de temperatura do ar (T_{ar}), umidade específica (q) e umidade relativa do ar (UR) para a região Centro-Oeste do Brasil.....	66
TABELA 9 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da temperatura do ar máxima ($T_{ar_{máx}}$) nas escalas diária, mensal e anual pelos produtos CPC, ERA5-LAND, GLDAS, JRA55, MERRA-2, NCEP/DOE e ENSEMBLE para a região Centro-Oeste do Brasil.....	93
TABELA 10 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman	

(r), coeficiente de concordância de Lin (ρ_c) e Pbias da temperatura do ar máxima (Tarmáx).....	94
TABELA 11 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da temperatura do ar média (Tar _{méd}) nas escalas diária, mensal e anual pelos produtos CPC, ERA5-LAND, GLDAS, JRA55, MERRA-2, NCEP/DOE e ENSEMBLE para a região Centro-Oeste do Brasil.	96
TABELA 12 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da temperatura do ar média (Tarméd).....	97
TABELA 13 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da temperatura do ar mínima (Tar _{mín}) nas escalas diária, mensal e anual pelos produtos CPC, ERA5-LAND, GLDAS, JRA55, MERRA-2, NCEP/DOE e ENSEMBLE para a região Centro-Oeste do Brasil.	99
TABELA 14 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da temperatura do ar mínima (Tar _{mín}) para os biomas Amazônia, Cerrado, Pantanal e Mata Atlântica dos produtos CPC, ERA-5, GLDAS, JRA55, MERRA-2, NCEP/DOE e ENSEMBLE para a região Centro-Oeste do Brasil.	100
TABELA 15 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da umidade relativa do ar (UR) nas escalas diária, mensal e anual pelos produtos ERA5-LAND, GLDAS, JRA55 e NCEP/DOE para a região Centro-Oeste do Brasil.....	102
TABELA 16 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da umidade relativa do ar (UR) para os biomas Amazônia, Cerrado, Pantanal e Mata Atlântica dos produtos ERA5-LAND, GLDAS, JRA55 e NCEP/DOE para a região Centro-Oeste do Brasil.	103

TABELA 17 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias do déficit de pressão de vapor (DPV) nas escalas diária, mensal e anual pelos produtos ERA5-LAND, GLDAS, JRA55 e NCEP/DOE para a região Centro-Oeste do Brasil.....	103
TABELA 18 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias do déficit de pressão de vapor (DPV) para os biomas Amazônia, Cerrado, Pantanal e Mata Atlântica dos produtos ERA5-LAND, GLDAS, JRA55 e NCEP/DOE para a região Centro-Oeste do Brasil.	104
TABELA 19 Descrição das estações meteorológicas automáticas de superfície e disponibilidade dos dados utilizados para validar as estimativas dos produtos de temperatura do ar média, máxima e mínima, umidade relativa do ar e deficit de pressão de vapor estimados pelo CPC, CHIRPS, ERA-5, GLDAS, GPCP, GPM, JRA-55, MERRA-2, NCEP/DOE e TRMM para a região Centro-Oeste do Brasil.	110

LISTA DE SIGLAS E ABREVIATURAS

ρ_c	Concordância de Lin
4D-Var	Variacionais quadridimensionais
CHIRPS	Climate Hazards Group InfraRed Precipitation with Station
COOP	Cooperative Observer Network
CORRA	Combined Ku Radar-Radiometer Algorithm
CPC	Climate Prediction Center
<i>d</i>	Índice de Willmott
DF	Distrito Federal
DPV	Déficit de pressão de vapor
<i>e</i>	Pressão de vapor
ECMWF's	European Centre for Medium-Range Weather Forecasts
<i>es</i>	Saturação de pressão de vapor
EWEX	Global Climate and Energy Exchange Project
Geo-IR	Geostationary Infrared
GEOS	Goddard Earth Observing System
GLDAS	Global Land Data Assimilation System
GO	Goiás
GPCP	Global Precipitation Climatology Project
GPM	Global Precipitation Measurement
GSFC	Goddard Space Flight Center
GSI	Gridpoint Statistical Interpolation
IC	Intervalo de confiança
JRA-55	Japanese 55-year Reanalysis Project
LIS	Sensor de Imagens de Raios
MAE	Mean Absolut Error
MERRA-2	Modern-Era Retrospective Analysis for Research and Applications
MR	Modelo abrangente
MS	Mato Grosso do Sul
MT	Mato Grosso
NCEP-DOE	National Centers for Environmental Prediction and the National Center for Atmospheric Research

PBIAS	Percentual de viés
Ppt	Precipitação
<i>q</i>	Umidade específica
<i>r</i>	Correlação de Spearman
RMSE	Root Mean Squared Error
Tar	Temperatura do ar
Tar_{max}	Temperatura do ar máxima
Tar_{med}	Temperatura do ar média
Tar_{min}	Temperatura do ar mínima
TRMM	Tropical Rainfall Measurement Mission
<i>u</i>	Componente zonal do vento
UR	Umidade relativa do ar
<i>v</i>	Componente meridional do vento
<i>V</i>	Velocidade do vento
VarBC	Viés variacional
VIRS	Sensor de Luz Visível e Infravermelho
WCRP	World Climate Research Program
ZCAS	Zona de Convergência do Atlântico Sul

RESUMO

LOTUFO, J. B. S. **Validação de elementos climáticos estimados por sensoriamento remoto e reanálises na região Centro-Oeste do Brasil.** 2023. 132f. Tese (Doutorado em Física Ambiental), Instituto Física, Programa De Pós-Graduação em Física Ambiental, Universidade Federal de Mato Grosso, Cuiabá.

A região Centro-Oeste do Brasil desempenha um papel crucial na economia nacional, sendo reconhecida como um dos principais polos de produção agropecuária do país. Com uma extensa área territorial, complexidade de biomas e variedade geomorfológica, a região contribui significativamente para a variabilidade climática do Brasil. No entanto, a obtenção de dados climatológicos nessa área é desafiadora devido à heterogeneidade na distribuição de estações meteorológicas convencionais e à complexidade dos biomas locais. Diante desse cenário, o uso de produtos de sensoriamento remoto e reanálises tem sido explorado como uma alternativa para suprir a falta de dados climáticos convencionais. Esses métodos oferecem estimativas precisas e contínuas da distribuição espacial e temporal de variáveis climáticas, preenchendo as lacunas deixadas pela falta de estações meteorológicas tradicionais. As reanálises, em particular, fornecem dados em grade, possibilitando uma análise detalhada dos padrões climáticos em diferentes escalas. O presente estudo teve como objetivo validar dados estimados por diferentes produtos de sensoriamento remoto e reanálises para variáveis climáticas essenciais, como velocidade do vento, precipitação, temperatura do ar, umidade relativa e déficit de pressão de vapor na região Centro-Oeste. Utilizando dados de 120 estações meteorológicas automáticas distribuídas pela região, os conjuntos de dados avaliados incluíram CPC, CHIRPS, ERA-5, GLDAS, GPCP, GPM, JRA-55, MERRA-2, NCEP/DOE e TRMM. A pesquisa foi dividida em três capítulos dedicados a variáveis específicas: velocidade do vento (Capítulo I), precipitação (Capítulo II), temperatura do ar, umidade relativa do ar e déficit de pressão de vapor (Capítulo III). Cada capítulo abrangeu diferentes escalas temporais e biomas, proporcionando uma análise abrangente das condições climáticas na região. No Capítulo I, dedicado à Velocidade do Vento, observou-se que o ERA5-Land apresentou o melhor desempenho em escalas diária, mensal e anual para as regiões dos biomas Amazônia, Cerrado e Mata Atlântica. Entretanto, para o

Pantanal, o GLDAS demonstrou ser mais eficaz, evidenciando a necessidade de considerar as características específicas de cada bioma na interpretação dos resultados. No Capítulo II, referente à Precipitação, o CPC alcançou o melhor desempenho na escala diária, enquanto o ensemble de modelos obteve a melhor performance nas escalas mensal e anual. As superestimções e subestimções variaram nos diferentes biomas, destacando a importância de avaliar o desempenho dos modelos em contextos regionais específicos. No Capítulo III, abordando a temperatura do ar, umidade relativa do ar e déficit de pressão de vapor, foram identificados padrões distintos de desempenho. O CPC se destacou na temperatura do ar máxima, enquanto o ensemble foi superior em escalas mensal e anual. O ERA5-Land mostrou consistência como o melhor desempenho em umidade relativa do ar e déficit de pressão de vapor em todas as escalas e biomas. O estudo destaca a necessidade de validação e ajustes adequados à região, considerando a complexidade dos biomas e variabilidade climática específica. Os resultados fornecem informações valiosas para setores estratégicos, como energia renovável, infraestruturas civis, agricultura e previsão climática, contribuindo para uma compreensão mais robusta das condições climáticas na região Centro-Oeste do Brasil. O estudo destaca a necessidade contínua de pesquisas aprofundadas e ajustes específicos para cada bioma, visando aprimorar a confiabilidade das estimativas climáticas na região.

Palavras-Chave: Modelo de Performance; América do Sul; Análises Estatísticas.

ABSTRACT

LOTUFO, J. B. S. **Validation of climatic elements estimated by remote sensing and reanalysis in the Central-West region of Brazil.** 2023. 132f. Thesis (Doctorate in Environmental Physics), Physics Institute, Postgraduate Program in Environmental Physics, Federal University of Mato Grosso, Cuiabá.

The Central-West region of Brazil plays a crucial role in the national economy, being recognized as one of the main agricultural production hubs in the country. With an extensive territorial area, complexity of biomes and geomorphological variety, the region contributes significantly to Brazil's climate variability. However, obtaining climatological data in this area is challenging due to the heterogeneity in the distribution of conventional meteorological stations and the complexity of local biomes. Given this scenario, the use of remote sensing and reanalysis products has been explored as an alternative to overcome the lack of conventional climate data. These methods provide accurate and continuous estimates of the spatial and temporal distribution of climate variables, filling the gaps left by the lack of traditional weather stations. Reanalyses, in particular, provide gridded data, enabling detailed analysis of climate patterns at different scales. The present study aimed to validate data estimated by different remote sensing products and reanalysis for essential climate variables, such as wind speed, precipitation, air temperature, relative humidity and vapor pressure deficit in the Midwest region. Using data from 120 automatic weather stations distributed across the region, the datasets evaluated included CPC, CHIRPS, ERA-5, GLDAS, GPCP, GPM, JRA-55, MERRA-2, NCEP/DOE and TRMM. The research was divided into three chapters dedicated to specific variables: wind speed (Chapter I), precipitation (Chapter II), air temperature, relative humidity and vapor pressure deficit (Chapter III). Each chapter covered different time scales and biomes, providing a comprehensive analysis of climatic conditions in the region. In Chapter I, dedicated to Wind Speed, it was observed that ERA5-Land presented the best performance on daily, monthly and annual scales for the Amazon, Cerrado and Atlantic Forest biome regions. However, for the Pantanal, GLDAS proved to be more effective, highlighting the need to consider the specific characteristics of each biome when interpreting the results. In Chapter II, referring to Precipitation, the CPC

achieved the best performance on the daily scale, while the model ensemble obtained the best performance on the monthly and annual scales. Overestimations and underestimations varied across different biomes, highlighting the importance of evaluating model performance in specific regional contexts. In Chapter III, addressing air temperature, relative humidity and vapor pressure deficit, distinct performance patterns were identified. The CPC excelled in maximum air temperature, while the ensemble was superior on monthly and annual scales. ERA5-Land showed consistency as the best performance in relative humidity and vapor pressure deficit across all scales and biomes. The study highlights the need for validation and adjustments appropriate to the region, considering the complexity of biomes and specific climate variability. The results provide valuable information for strategic sectors, such as renewable energy, civil infrastructure, agriculture and climate forecasting, contributing to a more robust understanding of climate conditions in the Central-West region of Brazil. The study highlights the continued need for in-depth research and specific adjustments for each biome, aiming to improve the reliability of climate estimates in the region.

Keywords: Performance Model; South America; Statistical Analysis.

1. INTRODUÇÃO

A região Centro-Oeste do Brasil desempenha um papel preponderante na economia nacional, destacando-se como um dos principais polos de produção agropecuária no país (GODINHO et al., 2020). Além da relevância agrícola, sua vasta extensão territorial, marcada por uma complexidade única de biomas e diversidade geomorfológica, constitui um contribuinte significativo para a variabilidade climática regional (ROCHA et al., 2018; ALVES et al., 2020; SOUZA et al., 2021). Assim, a obtenção e análise de variáveis climáticas tornam-se imperativas para a compreensão dos processos climáticos subjacentes, com implicações cruciais em diversas aplicações científicas, agrícolas, ambientais e de planejamento. Contudo, a obtenção de dados climáticos precisos, abrangendo toda a região Centro-Oeste, é desafiadora. A heterogeneidade na distribuição das estações meteorológicas, derivada da vastidão territorial e complexidade da região, impõe limitações metodológicas, técnicas e geográficas ao acesso a dados. A importância das variáveis climáticas e as dificuldades enfrentadas para sua aquisição são enfatizadas em estudos científicos recentes (BASSETTO et al., 2019; OLIVEIRA et al., 2022).

Nesse contexto, visando fomentar o progresso socioeconômico regional, torna-se essencial investir em tecnologias e estratégias voltadas para o monitoramento e previsão das condições climáticas locais (de MORAES & GONÇALVES, 2023). Métodos alternativos, como sensoriamento remoto e reanálises climáticas, têm demonstrado eficácia ao aprimorar a qualidade e acessibilidade de informações climáticas, desempenhando um papel crucial na obtenção de dados mais abrangentes e precisos, contribuindo substancialmente para a pesquisa climática, a tomada de decisões e a gestão de recursos naturais na região (JUNIOR et al., 2021).

Recentemente, a disponibilidade de conjuntos de dados derivados de satélite, atualizados em tempo quase real e abrangendo quase duas décadas de informações, tem contribuído significativamente para o monitoramento e caracterização de padrões climáticos (GOUVEIA et al., 2022). Os satélites, ao orbitarem a Terra e coletarem dados em tempo real sobre a atmosfera, superfície terrestre e oceanos por meio de sensores, possibilitam o monitoramento de condições climáticas, previsão do tempo e diversas outras aplicações (ALMAGRO et al., 2021). Dessa forma, o sensoriamento remoto emerge como uma ferramenta crucial para o monitoramento e obtenção de dados climáticos, proporcionando livre acesso aos

dados, estimativas precisas e contínuas da distribuição espacial, com elevada resolução espacial e temporal (JIANG et al., 2021).

A evolução na disponibilidade de dados obtidos por satélite relaciona-se também ao uso das reanálises como ferramenta para a obtenção de dados meteorológicos. Esses produtos integram observações de campo, dados de satélite e modelos numéricos de previsão do tempo, gerando informações consistentes sobre as condições meteorológicas. As reanálises fornecem dados em grade, possibilitando uma análise detalhada dos padrões climáticos em diferentes escalas espaciais e temporais. As grades climáticas permitem a interpolação espacial dos dados disponíveis, preenchendo lacunas e fornecendo informações em locais não abrangidos por estações meteorológicas convencionais (AGUTU et al., 2017).

A combinação de produtos de sensoriamento remoto, reanálises e observações tem sido amplamente explorada na literatura científica recente para uma compreensão abrangente dos padrões climáticos. Estudos de alto impacto destacam a importância dessa abordagem para análises mais precisas e completas, contribuindo de forma significativa para a compreensão dos processos climáticos, a previsão de eventos extremos e o suporte à tomada de decisões em diversos setores (SMITH et al., 2022; GARCIA et al., 2023). Entretanto, é essencial considerar que a aplicação desses produtos na região Centro-Oeste do Brasil demanda validação e ajustes adequados, dado o contexto de variabilidade espacial, temporal e de parâmetros climáticos específicos dessa região (SILVA et al., 2021; OLIVEIRA et al., 2022).

1.1.Objetivo Geral

Identificar quais produtos estimados por satélite e reanálises climáticas (velocidade do vento, precipitação, temperatura do ar, umidade relativa do ar e déficit de pressão de vapor) são mais representativos para a região Centro-Oeste do Brasil.

1.2.Objetivos Específicos

- i. Avaliar os erros e incertezas produzidas pelos produtos de satélites e reanálises ao estimar os elementos climáticos em relação aos biomas (Amazônia, Cerrado, Mata Atlântica e Pantanal) e em escalas de tempo (diária, mensal e anual);

- ii. Verificar a correlação e a concordância entre os produtos e os valores observados dos elementos climáticos em relação aos biomas (Amazônia, Cerrado, Mata Atlântica e Pantanal) e escalas de tempo (diária, mensal e anual);
- iii. Validar produtos de satélites e reanálises de variáveis climáticas para os biomas do Centro-Oeste;

2. FUNDAMENTAÇÃO TEÓRICA

2.1. VARIÁVEIS METEOROLÓGICAS

As variáveis climáticas são parâmetros essenciais para o estudo e a compreensão dos sistemas climáticos (PANDA; SAHU, 2019). Nesta revisão, nos concentramos nas seguintes variáveis: velocidade do vento, precipitação, temperatura do ar, umidade relativa do ar e déficit de pressão de vapor. Essas variáveis têm influência direta sobre os processos meteorológicos e climáticos, além de desempenharem um papel crucial em estudos de mudanças climáticas e avaliação de impactos ambientais (LEVIZZANI; CATTANI, 2019).

A coleta de dados climáticos envolve a utilização de diversas fontes, como estações meteorológicas convencionais, torres de monitoramento, sensores remotos (satélites) e modelos de reanálise (LÓPEZ-BERMEIO et al., 2022). Cada fonte possui suas próprias técnicas de medição e procedimentos de qualidade dos dados, que devem ser considerados ao realizar análises climáticas (ARAUJO PALHARINI et al., 2021). Estudos recentes têm buscado avançar na análise e interpretação das variáveis climáticas em diferentes escalas espaciais e temporais. Esses avanços têm permitido melhorar a compreensão dos padrões climáticos, identificar tendências de longo prazo e fornecer informações relevantes para a adaptação e a mitigação das mudanças climáticas (GAO et al., 2018).

O estudo das variáveis climáticas desempenha um papel crucial em diversas aplicações, como a previsão do tempo, gestão de recursos hídricos, agricultura de precisão e tomada de decisões (VENTURA et al., 2016). Contudo, enfrenta desafios significativos relacionados à coleta e interpretação dessas variáveis, uma vez que a disponibilidade e qualidade dos dados variam entre regiões e períodos temporais, dificultando a análise consistente (ALEXANDER et al., 2019). Além disso, fatores como exposição a condições climáticas extremas, manutenção adequada de instrumentos e a variabilidade espacial e temporal dos fenômenos climáticos influenciam as técnicas de medição (THORNE et al., 2017).

No contexto da climatologia, a variável "velocidade do vento" desempenha um papel crucial na dinâmica atmosférica e na compreensão das mudanças climáticas regionais. Resultantes do deslocamento horizontal do ar causado por gradientes de pressão, os ventos têm intensidade e direção influenciadas pela variação de energia na superfície terrestre. A medição da velocidade do vento é realizada por anemômetros, como copos giratórios, hélices ou sensores de pressão, projetados para capturar diferentes aspectos dessa variável (VAREJÃO-SILVA,

2006). A velocidade do vento é afetada por fatores como a rugosidade da superfície, a distância vertical acima do solo e forças como o gradiente de pressão, atrito e a força de Coriolis. Essa variável é medida em metros por segundo (m/s) ou outras unidades, dependendo do contexto, e é influenciada por gradientes de pressão, topografia, temperatura atmosférica e características da superfície terrestre (ZHANG et al., 2022). A compreensão desses aspectos é fundamental para a análise climática e a aplicação em diferentes setores, destacando a interconexão entre a pesquisa climatológica e suas implicações prática. A medição da velocidade do vento é realizada por anemômetros, instrumentos como copos giratórios, hélices ou sensores de pressão, projetados para capturar diferentes aspectos da velocidade e direção do vento (OMETTO, 1981; VAREJÃO-SILVA, 2006).

O impulsionador primordial da velocidade do vento reside no gradiente de pressão atmosférica, um fenômeno que origina discrepâncias de pressão entre regiões contíguas, compelindo, assim, a movimentação do ar das zonas de alta pressão para aquelas de baixa pressão (VAREJÃO-SILVA, 2006). Esta dinâmica desempenha um papel crucial na formação dos ventos atmosféricos. Além disso, a temperatura do ar exerce uma influência significativa na geração do vento. As disparidades de temperatura entre diferentes áreas criam gradientes de densidade que impactam o deslocamento do ar. Tais interações entre gradientes de pressão e temperatura são fundamentais para a compreensão da dinâmica atmosférica e para elucidar a variação na velocidade do vento em diversos contextos climáticos (VAREJÃO-SILVA, 2006; PEREIRA et al., 2007).

A variabilidade da velocidade do vento é notável ao longo do tempo e do espaço. Regiões costeiras podem experimentar padrões diários de vento devido à brisa marítima, enquanto áreas montanhosas podem ser sujeitas a acelerações ou desacelerações do vento devido à topografia. Além disso, as mudanças climáticas globais também podem influenciar a variabilidade da velocidade do vento em escala regional (COUTO et al., 2023; DE ARAÚJO SANTOS et al., 2023). A medição precisa dessa variável é essencial para entender padrões atmosféricos, prever eventos climáticos e otimizar tecnologias relacionadas à energia eólica.

A importância da velocidade do vento na análise das mudanças climáticas regionais e na modelagem de eventos climáticos extremos é destacada na pesquisa (ZHANG et al., 2022). Compreender essas mudanças é crucial para antecipar impactos ambientais significativos. A variável velocidade do vento é amplamente empregada em trabalhos científicos que buscam entender os padrões climáticos regionais, como as monções, e investigar mudanças na velocidade do vento em resposta às mudanças climáticas globais (SMITH et al., 2010;

OLIVEIRA et al., 2019; CHEN et al., 2021). Em resumo, essa variável climática tem implicações práticas abrangentes e seu entendimento é fundamental para avanços na pesquisa climatológica, meteorológica e para a tomada de decisões em setores que dependem dela.

Ao considerar a precipitação, fenômeno que se refere à descarga de água da atmosfera sobre a superfície terrestre, observa-se sua relevância no ciclo hidrológico da Terra. A precipitação, em suas diversas formas, desempenha papel crucial no abastecimento de água doce em lagos, rios e aquíferos, sendo fundamental para a preservação da vida e a manutenção do equilíbrio ambiental (OMETTO, 1981; VAREJÃO-SILVA, 2006). Além disso, a quantidade, intensidade e frequência da precipitação variam em diferentes regiões e climas, impactando a produtividade agrícola e a geração de energia em usinas hidrelétricas (SILVA et al., 2022; PERES et al., 2022). A compreensão e monitoramento desse fenômeno são essenciais para diversas aplicações, incluindo previsões climáticas, gestão de recursos hídricos e estudos climatológicos (TOMASELLA et al., 2023). A quantidade de precipitação é comumente expressa pela espessura da camada d'água que se formaria sobre uma superfície horizontal, plana e impermeável, com 1m² de área. A unidade de medida adotada é o milímetro, equivalente à queda de um litro de água por metro quadrado da projeção da superfície terrestre. A precipitação é caracterizada por sua duração e intensidade, esta última representando a quantidade de água que cai por unidade de tempo. Os dispositivos utilizados para medir a precipitação diretamente são chamados de pluviômetros, enquanto os registradores são conhecidos como pluviógrafos (VAREJÃO-SILVA, 2006).

A ocorrência e distribuição da chuva são processos complexos, influenciados por uma série de fatores atmosféricos e geográficos, conforme evidenciado por estudos científicos recentes. A temperatura atmosférica é um desses fatores cruciais, pois afeta diretamente a capacidade do ar de conter vapor d'água. Estudos relacionam as implicações das variações térmicas na formação de sistemas de chuva, oferecendo insights sobre a relação entre temperatura e precipitação (LI, et al., 2019). Outro elemento que influencia na dinâmica das chuvas é a umidade atmosférica. A quantidade de vapor d'água presente na atmosfera desempenha um papel determinante na formação de nuvens e, conseqüentemente, na ocorrência de precipitação. Estudos corroboram com a afirmativa, onde analisam a relação entre a umidade atmosférica e os padrões de chuva em diferentes regiões do globo (O'GORMAN & MULLER, 2016).

A topografia e elevação do terreno também exercem influência na distribuição da chuva. Áreas montanhosas podem modificar a trajetória do ar úmido, afetando os padrões de

precipitação. A topografia modula os padrões de chuva em escalas regionais, contribuindo para uma compreensão mais abrangente desses fenômenos (SMITH et al., 2020). Os padrões de circulação atmosférica, como os sistemas de alta e baixa pressão, são outros fatores significativos na distribuição da chuva (HOSKINS & HODGES, 2021). A precipitação é uma das variáveis mais importantes utilizadas nos estudos de mudanças climáticas (SOL et al., 2021). Estudos, como os do Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2018), examinam projeções futuras relacionadas às mudanças climáticas e seus efeitos na ocorrência de eventos extremos de chuva. eventos climáticos como El Niño e La Niña, e fatores regionais específicos (TRENBERTH et al., 2021). Esses fatores atuam de maneira interconectada, e a compreensão de suas complexas relações é crucial para prever padrões de chuva e antecipar seus impactos. A pesquisa contínua na área de climatologia e meteorologia é essencial para aprofundar nosso entendimento desses fenômenos e para o desenvolvimento de estratégias de adaptação e mitigação em face das mudanças climáticas.

A distribuição de energia na superfície terrestre é influenciada por vários fatores e desempenha um papel crucial em processos físicos, destacando-se o fluxo convectivo de calor sensível, intrinsecamente ligado à temperatura do ar. O aquecimento atmosférico resulta da transferência de energia entre a superfície do solo e as camadas de ar adjacentes, seguindo o gradiente térmico presente no perfil atmosférico (OMETTO, 1981; AYODE, 1996; VAREJÃO-SILVA, 2006). Em uma escala macroclimática, fatores como altitude, latitude, irradiação solar, ventos, nebulosidade, transporte convectivo de calor e concentração de vapor d'água na atmosfera exercem papéis preponderantes na influência da distribuição de energia e, conseqüentemente, na variação da temperatura do ar. Na escala topoclimática, a tipologia do relevo assume relevância, enquanto, na escala microclimática, a cobertura do solo desempenha um papel fundamental (PEREIRA et al., 2002).

Observa-se que as variações sazonais de temperatura estão diretamente correlacionadas à variação na radiação solar, resultando em temperaturas mais elevadas no verão e mais baixas no inverno. Em regiões extratropicais, especialmente em áreas interiores continentais, as variações sazonais na temperatura do ar são mais pronunciadas, enquanto nas proximidades da faixa equatorial, são menos acentuadas. Argumenta-se, portanto, que as variações sazonais de temperatura aumentam com a latitude e com a continentalidade (AYODE, 1996). A mensuração da temperatura do ar é realizada por meio de termômetros e termógrafos. Em contextos meteorológicos e climatológicos, estabelece-se uma área padrão, plana e gramada para permitir comparações entre diferentes locais. Nas estações climatológicas, os dispositivos são instalados

em abrigos termométricos, protegendo-os das intempéries. Diversos modelos de termômetros estão disponíveis, incluindo termômetros de extremas, que registram temperaturas máximas e mínimas. A instalação deve ocorrer a uma altura de 1,25 a 2 metros acima da superfície, com as unidades de medida podendo ser Celsius, Fahrenheit e Kelvin (PEREIRA et al., 2002; VAREJÃO-SILVA, 2006; FRANCO, 2010).

A temperatura do ar, sendo uma das variáveis meteorológicas mais significativas, destaca-se em estudos nas áreas de saúde, ambiente, agricultura, entre outras. Compreender sua variação temporal e espacial é essencial para investigações sobre tempo e clima regionais, zoneamento agroclimático, avaliação de riscos para produções agrícolas e florestais, caracterização de eventos extremos, estudo da distribuição de espécies vegetais nativas, análise de conforto térmico, estimativa de radiação solar global, evapotranspiração e avaliação dos impactos das mudanças climáticas (LYRA et al., 2011; MEDEIROS et al., 2018). Apesar de ser amplamente empregada em trabalhos científicos (HUANG et al., 2019; CANALES et al., 2020; OSBORN et al., 2021), a escassez de estações meteorológicas com séries temporais extensas de temperatura do ar no Brasil impõe desafios ao desenvolvimento de estudos que a envolvam.

A umidade relativa do ar (UR), expressa em porcentagem, representa a quantidade de vapor de água presente no ar em relação à quantidade máxima que o ar poderia conter a uma determinada temperatura (FROTA; SCHIFFER, 1995). Quando a umidade relativa atinge 100%, indica que o ar está saturado de água, podendo resultar em condensação (VIEIRA et al., 2010). De acordo com Kramer (1995) e Salisbury et al. (1992), a umidade relativa do ar é um dos fatores ambientais que impactam na transpiração vegetal, juntamente com a radiação solar, a temperatura e o vento. Aumentos na umidade ambiental estão associados a uma redução na transpiração, devido à diminuição do gradiente de pressão de vapor de água na folha e no ar circundante. Durante o dia, especialmente entre 12 e 14 horas, os valores de umidade relativa do ar e potencial hídrico aumentam consideravelmente, resultando em menor umidade relativa, maior déficit de pressão de vapor do ar e maior demanda evaporativa do ar (LACERDA, 2007).

A determinação da umidade relativa do ar pode ser realizada por meio de instrumentos conhecidos como psicrômetros, tradicionalmente constituídos por dois termômetros de mercúrio-em-vidro: um de bulbo seco e outro de bulbo úmido, coberto por um tecido molhado. Alternativamente, psicrômetros elétricos ventilados, que utilizam sensores resistivos, termopares ou termístores, têm ganhado preferência. Além disso, higrômetros, higrógrafos e termohigrógrafos medem diretamente a umidade relativa do ar através da variação do

comprimento de um feixe de cabelo humano em resposta às alterações na umidade relativa (VAREJÃO-SILVA, 2006).

Os elementos climáticos, incluindo a pressão atmosférica, temperatura, radiação solar e umidade do ar, conferem dinâmica ao clima. Por isso, realizar previsões precisas desses elementos é crucial para apoiar decisões em diversos setores (CARVALHO et al., 2016). Análises regulares e precisas da umidade relativa do ar em uma região específica podem ser valiosas, especialmente no planejamento do uso da terra com base em considerações climáticas, proporcionando insights para o desenvolvimento de práticas agrícolas mais sustentáveis.

A quantidade de vapor de água presente no ar e a quantidade máxima de vapor de água que o ar pode conter em determinada temperatura é denominada umidade relativa do ar (UR), sendo utilizada unidade de medida em porcentagem (FROTA; SCHIFFER, 1995). A UR leva em conta a quantidade de água existente no ar e a quantidade máxima de água que poderia existir, existe uma relação direta com a temperatura do ar, e quando a umidade relativa chega a 100% há uma indicação de que o ar está com quantidade máxima de água, podendo resultar em condensação (VIEIRA et al., 2010).

Segundo Kramer (1995); Salisbury et al (1992), a umidade relativa do ar é um dos fatores ambientais que influenciam na transpiração dos vegetais, bem como a radiação solar, a temperatura e o vento. Quanto maior a umidade ambiental, menor seria a transpiração, pois diminui o gradiente de pressão de vapor de água na folha e no ar que a envolve. Durante o dia, com o aumento da temperatura, principalmente entre 12 e 14 horas, os valores de umidade relativa do ar e de potencial hídrico sofrem um aumento considerável, acarretando menor potencial hídrico, menor umidade relativa, maior déficit de pressão de vapor do ar e maior demanda evaporativa do ar (LACERDA, 2007).

A determinação da umidade relativa do ar pode ser feita com o auxílio de instrumentos chamados de psicrômetros (do grego “*psychrós*”, que significa frio), além de ser possível medir de forma direta através de instrumentos apropriados. Os modelos convencionais de psicrômetro são constituídos por dois termômetros comuns (de mercúrio-em-vidro), um com bulbo descoberto e o outro com o bulbo revestido por um tecido fino (musselina, gaze etc.), molhado imediatamente antes do uso, de preferência com água destilada, são chamados respectivamente de termômetro de bulbo seco e úmido. Atualmente, os psicrômetros elétricos ventilados têm sido mais utilizados, pois usam como sensores resistências, termopares ou termístores. Os higrômetros, os higrógrafos e os termohigrógrafos são instrumentos que medem diretamente a

umidade relativa do ar através da variação do comprimento que experimenta um feixe de cabelo humano, diante da alteração da umidade relativa do ar (VAREJÃO-SILVA, 2006).

A explicação da pressão de vapor da água na atmosfera é fornecida pelo conceito de déficit de pressão de vapor (DPV), que representa a diferença entre a pressão exercida pela quantidade atual de vapor de água no ar em um determinado instante e temperatura (e_a ; pressão atual de vapor), e a pressão máxima que o mesmo ar pode atingir na mesma temperatura (e_s ; pressão de saturação) (LI et al., 2021). Essa diferença avalia a capacidade evaporativa do ar e está diretamente relacionada aos processos de evaporação, dependendo do gradiente de pressão de vapor entre a superfície evaporante e o ar, entre outros fatores. Quando o DPV é zero, o ar está 100% saturado com vapor de água. A umidade relativa da atmosfera, assim como a temperatura, desempenha um papel crucial no DPV. O aumento da temperatura e a diminuição da umidade aumentam a taxa de transpiração das plantas (LANCHER, 2001; VIEIRA, 2009; SCHOPFHAUSER, 2020).

O DPV é utilizado como indicador do potencial de condensação, permitindo a quantificação da proximidade do ponto de saturação do ar. O ar é considerado saturado quando atinge a capacidade máxima de retenção de água a uma dada temperatura. Quando a umidade do ar ultrapassa sua capacidade, ocorre a deposição de água líquida no ambiente. Em resumo, a pressão de vapor é uma medida da quantidade de água na forma de gás presente no ar (OMETO, 1981; VAREJÃO-SILVA, 2006; VIEIRA, 2009).

O DPV é uma variável essencial em modelos de estimativa de evaporação. No entanto, há relatos de escassez de registros de dados de umidade do ar, devido à coleta preferencial de dados de temperatura e precipitação nas estações meteorológicas (CASTELLVÍ et al., 1996). Assim, diversos métodos de cálculo de DPV estão descritos na literatura (DOORENBOS & PRUITT, 1975; SADLER & EVANS, 1989; JENSEN; BURMAN; ALLN, 1990; HOWELL; DUSEK, 1995; PEREIRA; VILLA NOVA; SEDIYAMA, 1997; ALLEN et al., 1998). Contudo, muitos desses métodos não são práticos, e as estimativas diferem estatisticamente (PEREIRA et al., 1997).

2.2.PRODUTOS DE SENSORIAMENTO REMOTO E REANÁLISES

O sensoriamento remoto é uma ferramenta científica poderosa que permite a observação e a coleta de informações sobre a superfície terrestre de forma não intrusiva (LEVIZZANI; CATTANI, 2019). Essa abordagem, baseada nos princípios da física eletromagnética, tem sido

amplamente utilizada em estudos científicos para compreender melhor o meio ambiente, monitorar mudanças, identificar padrões e obter dados valiosos para a tomada de decisões informadas (LEVIZZANI; CATTANI, 2019).

O sensoriamento remoto é fundamentado na interação entre a energia eletromagnética e os objetos presentes na superfície terrestre (MERTIKAS et al., 2021). A energia eletromagnética é capturada por sensores montados em plataformas aéreas, como satélites, aviões ou drones, e posteriormente processada e analisada para obter informações sobre as características dos objetos e materiais observados. O sensoriamento remoto tem sido amplamente aplicado em várias áreas do conhecimento. Na monitorização ambiental, essa técnica é utilizada para avaliar a saúde dos ecossistemas, monitorar a qualidade da água, detectar a poluição atmosférica e analisar a cobertura vegetal (MERTIKAS et al., 2021).

Na área climática, os dados de sensoriamento remoto são fundamentais para o estudo dos padrões climáticos, previsões meteorológicas e análise de mudanças climáticas (PEI et al., 2021). Embora o sensoriamento remoto seja uma técnica poderosa, existem desafios a serem superados (GOLUBKOV et al., 2020). Alguns desses desafios incluem a correção de distorções atmosféricas, a necessidade de processar grandes volumes de dados e a necessidade de integrar informações de diferentes fontes para obter uma visão abrangente do ambiente observado (GOLUBKOV et al., 2020).

O sensoriamento remoto está em constante evolução, com avanços tecnológicos que possibilitam a obtenção de dados de alta resolução espacial e espectral (PEI et al., 2021). Além disso, a disponibilidade crescente de dados gratuitos e de acesso aberto tem impulsionado a pesquisa científica e a colaboração entre instituições. Essas perspectivas prometem melhorar a compreensão do nosso planeta e a tomada de decisões informadas em áreas como a gestão ambiental, agrícola, urbana e climática (KUMAR et al., 2022). Neste contexto, o uso adequado e eficiente do sensoriamento remoto é fundamental para enfrentar os desafios ambientais e sociais que enfrentamos atualmente, bem como para impulsionar o progresso científico em direção a um futuro sustentável.

O GPCP é um conjunto de dados integrante do *Global Climate and Energy Exchange Project* (GEWEX) do *World Climate Research Program* (WCRP), que tem como objetivo manter um registro global homogêneo de estimativas de precipitação a longo prazo e fornecer informações relevantes para estudos climáticos (ABDELMONEIM et al., 2022). O GPCP utiliza informações disponíveis de precipitação de diferentes fontes, incluindo satélites e observações in situ, a fim de produzir um produto combinado com a melhor qualidade, em

escalas diárias, mensais, pentadal (cinco dias) e a cada três horas. Todos os produtos GPCP são internamente consistentes, e a estimativa diária é ajustada para manter a consistência. O produto diário utiliza as estimativas de precipitação do GPM IMERG para o intervalo de 55°NS e estimativas TOVS/AIRS ajustadas climatologicamente para o IMERG fora dos domínios de 55°NS (HUFFMAN et al., 2021).

O GPM (*IMERGDF v06*) produz suas estimativas de precipitação a partir do conjunto de dados GPM *IMERGHH*, simplesmente somando as recuperações de precipitação em escala de meia-hora válidas para o dia. O algoritmo IMERG usa o *Goddard Profiling Algorithm* (GPROF2017) para calcular as estimativas de precipitação dos vários sensores de micro-ondas passivos de satélite que compõem a constelação GPM. As estimativas são ajustadas pelo GPM *Combined Ku Radar-Radiometer Algorithm* (CORRA) para o produto mensal do GPCP sobre oceanos de alta latitude e terras tropicais para corrigir vieses conhecidos. As estimativas são combinadas em campos de 0,1° x 0,1° a cada meia hora e posteriormente em campos de 10 x 10 km para produzir o conjunto de dados GPM IMERG DF (SKOFRONICK-JACKSON et al., 2017).

O MERRA-2 é produzido utilizando a versão 5.12.4 do sistema de assimilação de dados atmosféricos *Goddard Earth Observing System* (GEOS), com o esquema de análise meteorológica *Gridpoint Statistical Interpolation* (GSI) de variação tridimensional (3DVAR) (RANGLES et al., 2017). O GSI utiliza um procedimento de atualização incremental a cada 6 horas, com a análise aplicada em uma grade de latitude-longitude com a mesma resolução espacial do modelo atmosférico (GEOS). A discretização do núcleo dinâmico é calculada em uma grade de esfera cúbica que atenua particularidades de espaçamento dos pontos de grade, com uma resolução aproximada de 50 km na grade nativa de esfera cúbica e 72 camadas híbridas-eta da superfície a 0.01 hPa. A maioria dos produtos é salva em uma grade padrão de 0.58 graus por 0.625 graus de latitude por longitude (GELARO et al., 2017).

O TRMM é especialmente projetado para estudar as características da precipitação nas regiões tropical e subtropical. O TRMM é equipado com vários sensores, incluindo o Radar de Precipitação TRMM *Microwave Imager* (TMI), o Sensor de Imagens de Raios (LIS) e o Sensor de Luz Visível e Infravermelho (VIRS). O algoritmo TRMM *Multi-satellite Precipitation Analysis* (TMPA) é utilizado para avaliar a precipitação, empregando estimativas de precipitação de vários sensores passivos de micro-ondas (PMW), *Geostationary Infrared* (Geo-IR) mesclado ajustado por micro-ondas e produtos do GPCC (HUFFMAN et al., 2007). O processo de produção do TMPA envolve quatro etapas: (1) estimação dos valores ideais das

observações do PMW usando a versão 2010 do algoritmo GPROF (GPROF2010); (2) criação de estimativas de precipitação Geo-IR a partir dos valores ótimos; (3) combinação intercompatível das estimativas PMW e Geo-IR; e (4) redimensionamento e calibração dos valores combinados com os dados do GPCC para gerar informações precisas sobre a precipitação tropical e subtropical (TAN & DUAN, 2017).

Os produtos de reanálise são conjuntos de dados essenciais para o estudo e compreensão do clima em diferentes escalas temporais e espaciais (GEHNE et al., 2016). Esses produtos são gerados através de um processo de combinação de observações reais com modelos de simulação climática, resultando em conjuntos de dados climáticos consistentes e contínuos (DUAN et al., 2016). Um dos principais tipos de produtos de reanálise são estimativas em tempo real de variáveis atmosféricas, tais como temperatura, pressão atmosférica, umidade, vento e outras.

Através da assimilação de observações meteorológicas, como dados de satélites, estações meteorológicas e boias oceânicas, é possível obter informações atualizadas sobre as condições atmosféricas em diferentes regiões do planeta (UPPALA et al., 2005). Além dos dados de análise em tempo real, os produtos de reanálise também incluem conjuntos de dados históricos (UPPALA et al., 2005). Esses conjuntos de dados abrangem um período de várias décadas e fornecem séries temporais de variáveis climáticas, como temperatura média, precipitação, radiação solar e outros parâmetros relevantes.

Com esses dados, os cientistas podem analisar as variações climáticas ao longo do tempo, identificar padrões climáticos recorrentes e estudar tendências de longo prazo. Os produtos de reanálise global são especialmente úteis para estudos climáticos em escala global (RAMON et al., 2019). Eles abrangem toda a superfície da Terra e fornecem informações detalhadas sobre a atmosfera e o oceano. Esses conjuntos de dados permitem o estudo de fenômenos climáticos importantes, e são fundamentais para a compreensão das mudanças climáticas globais e seus impactos (ALEXANDER et al., 2020). Em suma, os produtos de reanálise desempenham um papel crucial no estudo do clima.

O GLDAS é uma reanálise de nova geração desenvolvida pela NASA *Goddard Space Flight Center* (GSFC) e NCEP. Esse sistema global de modelagem terrestre de alta resolução utiliza vários modelos de superfície terrestre, observações terrestres, dados de satélite, medições de precipitação de radar e resultados de modelos de previsão numérica para produzir campos ideais de estados e fluxos de superfície terrestre em condições quase reais. Além disso, existem duas versões do GLDAS versão 2: o GLDAS-2.0, impulsionado inteiramente com dados de forçantes meteorológicas de Princeton e o GLDAS-2.1 que utiliza uma combinação de modelos

e conjuntos de dados observacionais como entradas para impulsionar o modelo (LIU et al., 2021).

O ERA5-Land é um conjunto de dados que se baseia nos sistemas de assimilação variacional 4D utilizados na reanálise climática ERA5-Land oferecendo uma visão coerente da evolução dos parâmetros que compõem o sistema terrestre, mas com resolução espacial aprimorada (XU et al., 2022). Estes sistemas de assimilação são fundamentados em técnicas de modelagem numérica, nas quais equações matemáticas são empregadas para representar as condições atmosféricas e da superfície terrestre. Com a finalidade de ajustar as condições simuladas às condições reais, as equações são alimentadas com informações observacionais provenientes de diversas fontes de dados, tais como satélites, estações meteorológicas e outras fontes relevantes (TAREK et al., 2020).

O JRA-55 se baseia em um novo sistema de assimilação e previsão de dados (DA), o qual corrigiu muitas das deficiências presentes na primeira reanálise japonesa JRA-25. Dentre as melhorias implementadas, destacam-se o aumento da resolução espacial, a adoção de um novo esquema de radiação, a assimilação de dados variacionais quadridimensionais (4D-Var) com correção de viés variacional (VarBC) para radiancias de satélite e a inclusão de gases de efeito estufa com concentrações variáveis no tempo (KOBAYASHI et al., 2015). Todo o processo de produção do JRA-55 foi finalizado em 2013 e, a partir de então, passou a ser atualizado em tempo real (CHEN et al., 2019).

O NCEP-2 dos Centros Nacionais de Previsão Ambiental (NCEP) é uma versão que atualizou as parametrizações dos processos físicos e corrigiu de erros humanos do NCEP, com dados de entrada e resoluções verticais semelhantes. O NCEP-2 adota um esquema de assimilação variacional tridimensional (3D-Var) e usa técnicas numéricas de previsão do tempo para assimilar e prever estados atmosféricos (PENG et al., 2019).

O CHIRPS (Climate Hazards group InfraRed Precipitation with Station data) é um conjunto de dados altamente preciso que fornece estimativas de precipitação em alta resolução espacial e temporal em todo o mundo. Para estimar a precipitação, o CHIRPS combina dados de satélite infravermelho e de micro-ondas com dados de pluviômetros. Nos locais onde os dados de pluviômetros são limitados ou inexistentes, o CHIRPS utiliza observações de satélite para fornecer estimativas. Em seguida, essas estimativas são combinadas com dados de pluviômetros para corrigir e calibrar as estimativas do satélite. Isso permite que o CHIRPS forneça estimativas de precipitação em uma resolução espacial extremamente detalhada, com

uma resolução de 0.05 graus (cerca de 5 km), e em uma resolução temporal diária, desde 1981 (FUNK et al., 2015).

O CPC *Global Unified Precipitation* é o primeiro produto resultante do Projeto de Precipitação Unificada, que está em andamento na Administração Nacional Oceânica e Atmosférica (NOAA). Esse projeto tem como objetivo combinar todas as fontes de informação disponíveis no CPC e utilizar técnicas avançadas de análise de interpolação para criar um conjunto de produtos de precipitação unificados com qualidade aprimorada e quantidade consistente. O CPC-Global utiliza relatórios de medição de cerca de 30.000 estações, incluindo dados do GTS, do *Cooperative Observer Network* (COOP) e de outras agências meteorológicas nacionais. Esse produto é atualizado diariamente e oferece estimativas de precipitação com uma resolução espacial de aproximadamente 0.5 graus de latitude e longitude, permitindo o monitoramento global da precipitação em tempo quase real (SUN et al., 2018).

2.3.VALIDÇÃO DOS PRODUTOS DE SENSORIAMENTO REMOTO E REANÁLISES

A verificação de dados oriundos de produtos de reanálise é uma prática disseminada em escala global, abrangendo diversas regiões geográficas. Estudos de validação têm sido conduzidos em variados cenários, contemplando ambientes terrestres (CHEN et al., 2020), regiões de baixas temperaturas (LINDSAY et al., 2014), áreas desérticas (ZHOU e WANG, 2016) e ecossistemas oceânicos (HOBBS et al., 2020). Este procedimento é considerado imperativo, configurando-se como um requisito essencial para assegurar a confiabilidade e a qualidade intrínseca dos dados obtidos por meio de processos modelísticos (FOIDL et al., 2019).

A validação em ambientes terrestres, conforme destacado por CHEN et al. (2020), compreende a confrontação dos dados de reanálise com observações efetuadas em terra firme. Tal abordagem visa verificar a coerência entre os registros modelados e as condições reais do meio ambiente terrestre. Em regiões de baixas temperaturas, conforme analisado por LINDSAY et al. (2014), a validação concentra-se nas áreas caracterizadas por climas frios, contribuindo para a aferição da acurácia dos dados em condições climáticas extremas. Já em ambientes desérticos, a validação, conforme investigada por Zhou e Wang (2016), envolve a comparação dos dados de reanálise com medições realizadas em regiões áridas. Este enfoque é essencial para avaliar a capacidade do modelo em reproduzir com precisão as características climáticas

particulares desses ecossistemas. No contexto oceânico, a validação de dados, conforme discutida por Hobbs et al. (2020), engloba a verificação da consistência entre os resultados modelados e as observações efetuadas nos oceanos. Este processo é fundamental para aferir a confiabilidade das informações geradas em relação aos fenômenos marinhos, contribuindo para a robustez e utilidade dos dados reanalisados. Em suma, a validação de dados provenientes de produtos de reanálise transcende fronteiras geográficas, sendo uma prática essencial para garantir a fidedignidade e a qualidade dos dados resultantes de processos modelísticos, o que é crucial para a compreensão precisa e confiável dos padrões climáticos em escala global.

3. ARTIGOS

A presente tese se estrutura em três capítulos, cada qual correspondendo a um artigo que valida produtos de satélite e reanálises de elementos climáticos. O primeiro capítulo concentra-se na análise da velocidade do vento, o segundo capítulo aborda a validação de dados de precipitação, e o terceiro capítulo direciona-se à validação da temperatura do ar, umidade relativa do ar e déficit de pressão de vapor. Cada capítulo desempenha um papel fundamental na compreensão e validação dessas variáveis climáticas, contribuindo para a robustez e a confiabilidade das informações utilizadas nas análises climatológicas para o Centro-Oeste do Brasil.

3.1 CAPÍTULO 1 – VALIDAÇÃO DE PRODUTOS DE SATÉLITE E REANÁLISE DE VELOCIDADE DO VENTO NO CENTRO-OESTE BRASILEIRO

RESUMO

Este estudo aborda a escassez de estações meteorológicas na região Centro-Oeste do Brasil, destacando a importância de reanálises climáticas e sensoriamento remoto para compensar essa falta de dados. A pesquisa visa validar a eficácia dessas ferramentas na obtenção de estimativas precisas da velocidade do vento, crucial para setores como energia renovável e planejamento de infraestruturas, especialmente na sensível Região Centro-Oeste. Neste estudo, a Região Centro-Oeste do Brasil, composta por Mato Grosso, Mato Grosso do Sul, Goiás e o Distrito Federal, é caracterizada por sua diversidade de biomas e climas. Destaca-se como a principal produtora de commodities do país, sendo essencial para a agricultura e pecuária. O trabalho utiliza dados de velocidade do vento provenientes de 120 estações meteorológicas automáticas, analisando medições de superfície a 10 metros acima do solo. Além disso, quatro produtos de reanálise (ERA5-Land, GLDAS, JRA-55, NCEP-DOE) e um de sensoriamento remoto (MERRA-2) são comparados com as observações locais. Indicadores de desempenho, como correlação de Spearman, concordância de Willmott e erro médio absoluto, são utilizados para avaliar a consistência dos dados. O estudo busca uma compreensão abrangente e precisa da velocidade do vento na Região Centro-Oeste, essencial para diversos setores, incluindo energia renovável, infraestruturas civis, agricultura e previsão climática. O estudo comparativo das estimativas de velocidade do vento provenientes de diferentes produtos de reanálise e

sensoriamento remoto na região Centro-Oeste do Brasil revelou notáveis disparidades e complexidades. Na escala diária, os produtos ERA5 e GLDAS apresentaram médias sem diferenças estatísticas em relação aos dados medidos, enquanto a reanálise MERRA-2 revelou superestimativa significativa. Em escalas mensais, ERA5 e GLDAS mantiveram médias dentro do intervalo de confiança, destacando-se positivamente em comparação com NCEP/DOE e MERRA-2, que exibiram superestimativas consideráveis. Na escala anual, ERA5, GLDAS e JRA55 não apresentaram diferenças estatísticas, contrastando com NCEP/DOE e MERRA-2, que mostraram superestimativas anuais significativas. Avaliações detalhadas por bioma indicaram padrões variados, evidenciando a necessidade de considerar a complexidade do sistema e suas variações temporais específicas. O ERA5 foi consistentemente destacado como um dos melhores em todas as escalas, enquanto o MERRA-2 revelou menor confiabilidade. A análise de Model Ranks (MR) corroborou essas tendências, destacando o desempenho superior do ERA5 em várias escalas temporais e biomas. Discussões sobre fatores influentes incluíram a resolução espacial, métodos de assimilação de dados, e a limitada disponibilidade de estações meteorológicas na região. Concluiu-se que a abordagem criteriosa na seleção de modelos é crucial, considerando as características específicas de cada bioma e a complexidade temporal das variações climáticas.

1.INTRODUÇÃO

A rede meteorológica nacional, derivada do Instituto Nacional de Meteorologia (INMET), indica que há variações substanciais na densidade de estações meteorológicas em todo o território brasileiro (XAVIER et al., 2016). Estados como Minas Gerais, Bahia, Rio Grande do Sul e São Paulo concentram aproximadamente um terço das 789 estações em operação, cobrindo apenas 20% da extensão territorial do país. Em contrapartida, Distrito Federal, Rio de Janeiro, Sergipe e Alagoas exibem uma concentração mais significativa de estações meteorológicas em seus territórios. No entanto, nove estados, representando 60% do território nacional - Roraima, Rondônia, Amazonas, Amapá, Pará, Acre, Mato Grosso, Maranhão e Tocantins possuem densidades de estações meteorológicas inferiores a 1 por 10.000 km² (SIEFERT et al., 2022). Essa disparidade na distribuição de estações meteorológicas cria desafios e incertezas ao tentar realizar interpolações a partir de dados observados. Desta maneira, para superar a escassez de dados em algumas regiões, as reanálises

climáticas tornaram-se produtos de grande relevância neste cenário (TEIXEIRA DE AGUIAR & LOBO, 2020).

As reanálises, ao integrar dados observados e informações remotas em modelos globais, desempenham um papel crucial na compreensão da dinâmica atmosférica, sendo fundamentais para modelagens climáticas e hidrológicas devido à sua consistência temporal e espacial (GELARO et al., 2017). A avaliação cuidadosa da adequação desses produtos é essencial, considerando a diversidade de opções disponíveis, suas aplicações específicas e a capacidade de adaptação aos dados observados, levando em conta as incertezas associadas (MANZANAS et al., 2019). Além disso, a escassez de dados de velocidade do vento em estações meteorológicas, particularmente em regiões críticas, destaca a necessidade de recorrer a fontes alternativas. A falta de séries temporais abrangentes nessas áreas reforça a importância de métodos como produtos de reanálises e sensoriamento remoto, capazes de fornecer dados confiáveis de velocidade do vento mesmo em locais onde as observações são limitadas. Essa abordagem é crucial para preencher lacunas e garantir uma compreensão mais abrangente e precisa das condições atmosféricas em diferentes partes do globo.

Estudos realizados na Alemanha e China avaliaram o desempenho dos produtos de reanálises em estimar dados de velocidade do vento, comparando-os diretamente com observações locais (CAÑADILLAS et al., 2023; ZHAI et al., 2023). Já no cenário brasileiro, estudos têm apontado para diferenças substanciais entre os dados de velocidade do vento derivados de reanálises e as medições locais (DE AQUINO FERREIRA et al., 2022; MARIANO et al., 2017; SIEFERT et al., 2022). Essa análise ganha ainda mais relevância quando contextualizada diante da desconhecida qualidade dos dados de reanálises na região Centro-Oeste do Brasil, onde é particularmente sensível às variações na velocidade do vento. Especificamente em escalas diárias e resoluções espaciais inferiores a 1 grau, a qual a incerteza associada a esses dados torna-se uma preocupação significativa. Neste cenário, esta condição ainda é agravada pela limitada disponibilidade de séries temporais abrangentes de dados observados no Brasil (BAATZ et al., 2021).

Recentes avanços no sensoriamento remoto e nas técnicas de reanálise climática têm viabilizado a obtenção precisa de estimativas da velocidade do vento em diversas altitudes e regiões geograficamente diversas. A integração cuidadosa dessas fontes de dados, aliada a processos de validação rigorosos, oferece uma compreensão detalhada das características do vento na Região Centro-Oeste (BHUIYAN et al., 2019). A acurácia dessas estimativas de vento desempenha um papel crucial em diversos campos científicos e aplicados. No contexto da

geração de energia renovável, a identificação de locais propícios para a instalação de parques eólicos e a otimização da eficiência na produção de energia dependem do conhecimento preciso da velocidade do vento. Ademais, dados precisos de vento são fundamentais para o planejamento seguro de infraestruturas civis, assim como para a tomada de decisões informadas na agricultura, monitoramento ambiental e previsão de eventos climáticos extremos. Este enfoque rigoroso estabelece uma base científica sólida, contribuindo para o avanço do conhecimento e das práticas em diversas disciplinas. Neste contexto, o objetivo deste manuscrito é validar produtos de reanálise e sensoriamento remoto da velocidade do vento na Região Centro-Oeste do Brasil.

2. MATERIAL E MÉTODOS

2.1 Área de Estudo

A região Centro-Oeste do Brasil é composta por três estados (FIGURA 1): Mato Grosso (MT), Mato Grosso do Sul (MS) e Goiás (GO), e o Distrito Federal (DF), onde está localizada a capital, Brasília. Esta região possui grande diversidade de vegetação, pois é composta por quatro dos seis biomas nacionais: a floresta amazônica, o cerrado, o pantanal e a mata atlântica. De acordo com a classificação de Köppen, o clima regional é Af (Floresta Tropical), Am (Monção), Aw (Savana com inverno seco), Cfa (Subtropical úmido), Cwa (Subtropical úmido com inverno seco) e Cwb (Alta altitude subtropical) (ALVARES et al., 2013). Esta região é conhecida por suas grandes áreas de produção agrícola e pecuária, sendo considerada a maior produtora de commodities do país (VILPOUX et al., 2021).

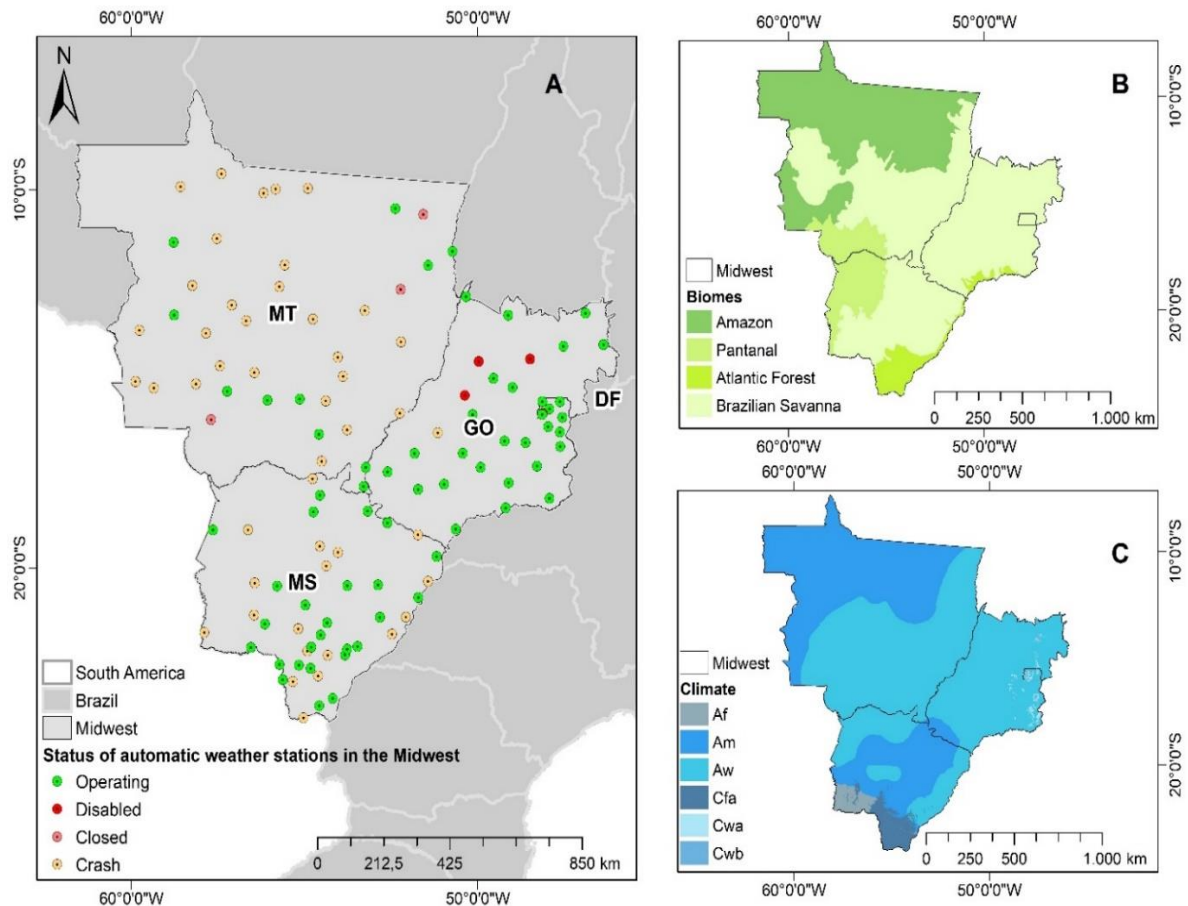


FIGURA 1 Estações meteorológicas da região Centro-Oeste do Brasil (A), biomas (B), clima (C).

2.2 Medições de Superfície

Os dados de velocidade do vento foram adquiridos do Instituto Nacional de Meteorologia (INMET) por meio do Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP). Usamos um conjunto de dados de 120 estações meteorológicas automáticas de 2000 a 2020 (Figura 1). Selecionamos estações meteorológicas automáticas com base na consistência e qualidade de suas séries temporais de longo prazo, com um número mínimo de observações faltantes (menos de 5 a 10%). Os valores horários foram determinados através de uma média diária. Os registros de velocidade do vento foram obtidos a uma altura de 10 metros acima do solo, seguindo as diretrizes estabelecidas pela Organização Meteorológica Mundial (OMM) (SANTOS & SILVA, 2013). Para integrar esses dados aos modelos utilizados na estimativa da velocidade do vento, realizamos uma conversão dos valores de 10 metros para 2 metros, empregando um ajuste logarítmico do gradiente do vento, conforme proposto por Allen et al. (1998).

2.3 Medições de Sensoriamento Remoto e Reanálises

Utilizamos quatro produtos de reanálise (ERA5-Land, GLDAS, JRA-55 e NCEP-DOE) e um produto de sensoriamento remoto (MERRA-2) (Tabela 1). Extraímos os dados dos produtos avaliados das células onde está localizada cada estação meteorológica automática. A velocidade do vento para os produtos ERA5-Land, JRA-55 e NCEP/DOE foi determinada calculando-a a partir do componente zonal (u) e componente meridional (v) através da equação $V = \sqrt{u^2 + v^2}$.

TABELA 1 Descrição do conjunto de dados de velocidade do vento de produtos de reanálise e 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° u	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

3. Indicadores de performance

As estimativas diárias, mensais e anuais da velocidade do vento de diferentes produtos foram avaliadas apenas quando não havia lacunas de dados nas observações das estações meteorológicas automáticas. Médias e intervalos de confiança ($\pm 95\%$) foram calculados utilizando a técnica de amostragem bootstrap com 1000 interações. O método bootstrap permite estimar amostras aleatórias repetidas para um conjunto de dados do mesmo tamanho da amostra original, e o intervalo de confiança indica a confiabilidade da estimativa.

O desempenho dos dados de velocidade do vento obtidos a partir de produtos de reanálise e sensoriamento remoto foi avaliado para determinar se os dados são consistentes com os dados observados. Foram utilizados os seguintes critérios de qualidade de ajuste: correlação de Spearman (r), concordância de Willmott (d), raiz do erro quadrático médio (RMSE), erro médio absoluto (MAE), concordância de Lin (ρ_c) e porcentagem de viés (PBIAS), conforme definido pelas equações abaixo.

TABELA 2 Métricas estatísticas para validar os produtos.

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)	$PBIAS = \frac{\sum (P_i - O_i)^2}{\sum O_i} \times 100 \quad (6)$	$PBIAS = 0$

Onde 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_x são as médias dos dois conjuntos.

As pontuações individuais nos permitem classificar os modelos com base nas métricas de desempenho (r , d , $RMSE$, MAE , ρ_c e $PBIAS$). Para resumir todas as possibilidades de classificação, a classificação abrangente do modelo (MR) também foi calculada (JIANG et al., 2015). MR é uma medida de quão consistentemente cada modelo é classificado entre todas as possibilidades de classificação:

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

onde 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).

4. RESULTADOS

Ao avaliar as médias e intervalos de confiança dos produtos de reanálise em comparação com os dados medidos, notou-se divergências significativas em diferentes escalas temporais. Em escala diária, os produtos ERA5 (1.87 ± 0.02 m/s) e GLDAS (2.01 ± 0.02 m/s) tiveram médias sem diferenças estatísticas com os dados medidos. Contudo, a reanálise GLDAS apresentou superestimativa diária ligeiramente superior (PBIAS: 15.9%). Por outro lado, a reanálise MERRA-2 (4.42 ± 0.05 m/s) teve uma superestimativa significativamente divergente dos dados medidos (PBIAS: 143.8%), indicando uma limitação na captura das variações diárias de velocidade do vento por parte desse modelo.

Em escala mensal, os produtos de reanálise ERA5 (1.88 ± 0.05 m/s) e GLDAS (2.01 ± 0.06 m/s) tiveram médias dentro do intervalo de confiança, indicando que não há diferença estatisticamente significativa em relação as medições (Figura 2). No entanto, destaca-se que a reanálise NCEP/DOE (2.68 ± 0.09 m/s) e MERRA-2 (4.43 ± 0.12 m/s) tiveram as maiores discrepâncias, indicando superestimativas mensais de 57.4% e 143.3%, respectivamente (Figura 2). Essa disparidade sugere que o NCEP/DOE e o MERRA 2 podem enfrentar desafios na reprodução de padrões mensais de velocidade do vento (Figura 2). Ao avaliar a escala anual, o ERA5, GLDAS e o JRA55 tiveram médias sem diferença estatística com os dados medidos (Figura 2). Por outro lado, o NCEP/DOE (PBIAS: 56.1%) e MERRA-2 (PBIAS: 140%) novamente com uma diferença estatística, indicando superestimativas anuais significativamente distintas das medições. Essa disparidade enfatiza a necessidade de levar em conta a variabilidade anual específica ao avaliar a confiabilidade dos modelos de reanálise (Figura 2).

De maneira geral, a análise das estimativas de velocidade do vento em diferentes biomas, empregando produtos de reanálise e sensoriamento remoto, destaca uma diversidade de padrões e discrepâncias entre as medições e as estimativas (Figura 2). Os produtos de reanálise e sensoriamento remoto demonstram respostas distintas considerando os biomas analisados, evidenciando a complexidade do sistema e seu impacto na qualidade das estimativas em relação às medições. Essa heterogeneidade nas respostas destaca a necessidade de uma abordagem detalhada e contextualizada para uma compreensão abrangente da precisão desses produtos climáticos, reconhecendo as particularidades específicas de cada bioma.

Na Amazônia, em escala diária, todos os produtos de reanálise e sensoriamento remoto exibiram médias que diferiram estatisticamente das medições. As maiores superestimativas

foram observadas nos produtos NCEP/DOE (44.4%) e MERRA-2 (50%). Em contrapartida, ERA5 (8.8%) e GLDAS (10.0%) apresentaram as menores superestimativas. No entanto, ao estender a análise para escalas mensais e anuais sobre a região, o cenário se altera, uma vez que as reanálises ERA5, GLDAS e JRA55 apresentaram médias dentro do intervalo de confiança das medições, apesar da alta variabilidade nos valores observados sobre a região (Figura 2).

No Cerrado, as estimativas provenientes do ERA5 não tiveram diferenças estatísticas significativas. No entanto, as estimativas do GLDAS indicaram médias com diferenças consideráveis, apresentando uma superestimativa de 13.0%. Em contrapartida, NCEP/DOE e MERRA-2 exibiram valores consideravelmente mais elevados, indicando superestimativas de 31.9% e 59.7%, respectivamente (Figura 2). Ao analisarmos os cenários mensais e anuais, observamos um padrão similar, onde as reanálises ERA5 (nas escalas mensal e anual) e GLDAS (na escala anual) não apresentaram diferenças estatisticamente significativas em relação aos dados medidos (Figura 2).

No Pantanal, as estimativas nas escalas diárias, mensais e anuais tiveram diferenças estatisticamente significativas. Em escala diária, tanto as estimativas do ERA5 quanto do JRA55 superestimaram os valores em comparação com as medições, apresentando superestimativas de 33.0% e 34.0%, respectivamente. O GLDAS, por sua vez, exibiu a menor superestimativa, registrando 28.0%. Em contrapartida, as reanálises MERRA-2 (68%) e NCEP/DOE (54%) tiveram as maiores superestimativas em relação às medições. Nas escalas mensais e anuais, o padrão das superestimativas se manteve, com as maiores divergências sendo exibidas pelos produtos NCEP/DOE e MERRA-2 (Figura 2).

Na Mata Atlântica, em escala diária, todas as estimativas dos produtos tiveram médias com diferenças estatísticas significativas em relação às medições. Em contraste, as estimativas mensais e anuais do ERA5 e as anuais do GLDAS não demonstraram médias estatisticamente diferentes das medições. No entanto, o MERRA-2 novamente apresentou a maior disparidade em relação às medições, registrando superestimativas de até 55.8% nas escalas mensais e

anuais. Adicionalmente, o NCEP/DOE também exibiu pronunciadas superestimativas (40.3%) (Figura 2).

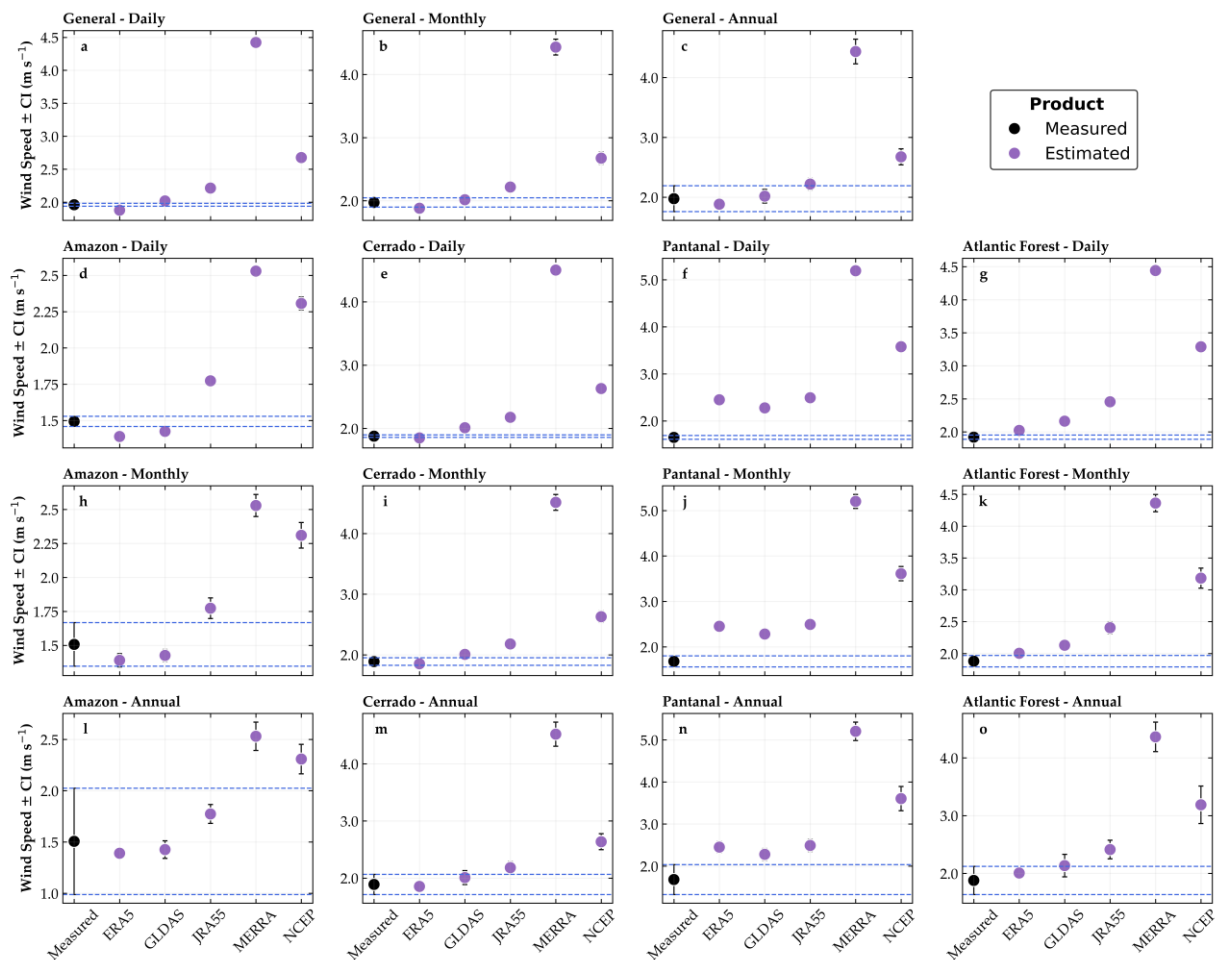


FIGURA 2 Valores médios de velocidade do vento \pm intervalo de confiança (IC) para medições diárias, mensais e anuais, para os biomas Amazônia, Cerrado, Pantanal e Mata Atlântica, medidas por estações meteorológicas automáticas do INMET e estimadas por produtos ERA-5, GLDAS, JRA-55, MERRA-2 e NCEP/DOE na região Centro Oeste do Brasil, de 2000 a 2020.

O produto ERA5 teve a pontuação mais elevada ($MR = 0.87$), indicando uma performance destacada em escala diária. O GLDAS também demonstra um desempenho sólido, embora inferior ao ERA5, com um $MR = 0.77$. Por outro lado, o MERRA2 registrou a pontuação mais baixa ($MR = 0.4$), sugerindo uma menor precisão nas estimativas diárias de velocidade do vento. No contexto das estimativas mensais, tanto o ERA5 quanto o GLDAS tiveram pontuações iguais (0.7), indicando um desempenho consistente e elevado ao longo desse intervalo de tempo. Por outro lado, o JRA55 apresentou uma pontuação intermediária (0.36), enquanto o MERRA2 e o NCEP/DOE exibiram pontuações mais baixas (0.06 e 0.17 , respectivamente) (Figura 3).

Ao avaliar a escala anual, o ERA5 manteve sua superioridade, obtendo a pontuação mais alta (0.73), seguido pelo GLDAS com uma pontuação de 0.67 . Por outro lado, o MERRA-2

novamente apresentou a pontuação mais baixa (0.06), sugerindo uma consistente subestimação em suas estimativas anuais. Numa avaliação geral por produto, o ERA5 destacou-se como um dos melhores em todas as escalas, mantendo uma consistência notável em sua precisão. Em contraste, o MERRA-2 revelou pontuações mais baixas em todas as escalas, indicando uma menor confiabilidade em suas estimativas de velocidade do vento (Figura 3).

Na Amazônia, a avaliação dos Model Ranks (MR) com diferentes produtos de reanálise revelou padrões distintos em escalas diárias, mensais e anuais. Na escala diária, o ERA5 e o GLDAS destacaram-se com MR de 0.85 e 0.725, indicando desempenho robusto e consistente. Em contraste, JRA55, MERRA-2 e NCEP apresentaram MR inferiores, sugerindo menor concordância com os dados medidos nessa escala temporal. Na escala mensal, o GLDAS manteve um desempenho notável (MR de 0.8), seguido pelo ERA5 (MR de 0.7), enquanto JRA55, MERRA-2 e NCEP mostraram MR mais baixos. Similarmente, na escala anual, o GLDAS e o ERA5 mantiveram MR superiores (0.75 e 0.7, respectivamente), indicando melhores performances em suas estimativas anuais (Figura 3).

No Cerrado em escala diária, as reanálises ERA5 e o GLDAS tiveram os MRs mais altos (0.85 e 0.7, respectivamente), indicando consistência e confiabilidade em suas estimativas (Figura 3). Em contraste, JRA55, MERRA-2 e NCEP/DOE apresentaram MRs mais baixos. Na escala mensal, o ERA5 manteve um desempenho robusto (MR de 0.85), enquanto o GLDAS demonstrou um MR de 0.73. Contudo, JRA55, MERRA e NCEP/DOE exibiram os menores valores de MR. Na escala anual, tanto o ERA5 quanto o GLDAS continuaram a se destacar com valores de MR mais elevados (0.85 e 0.7, respectivamente), indicando uma consistência notável em suas estimativas anuais. Em contraste, JRA55, MERRA e NCEP mantiveram MRs mais baixos, sugerindo possíveis limitações na reprodução de padrões tanto em todas as escalas temporais de velocidade do vento no bioma do Cerrado (Figura 3).

No bioma Pantanal, a avaliação dos Model Ranks (MR) revela uma superioridade do GLDAS em estimar a velocidade do vento nesta região. Em escala diária, o GLDAS demonstra o melhor desempenho, obtendo o MR mais alto (0.85), seguido pelo ERA5 com um MR de 0.65. Contudo, o MERRA apresenta um MR mais baixo (0.33), sugerindo possíveis limitações na captura de variações diárias de velocidade do vento. Na escala mensal, o GLDAS mantém um desempenho notável (MR de 0.75), enquanto o ERA5 e JRA55 exibem MRs de 0.57 e 0.65,

respectivamente. Já na escala anual, o GLDAS continua a se destacar com um MR de 0.73, indicando confiabilidade em suas estimativas anuais (Figura 3).

Na Mata Atlântica, em escala diária, o ERA5, teve o MR mais elevado (0.85), seguido pelo GLDAS, que alcançou um MR de 0.65. As reanálises JRA55 e NCEP apresentam MRs intermediários, enquanto o MERRA registra o MR mais baixo (0.28). Na escala mensal, o ERA5 com o maior MR de 0.70, enquanto o GLDAS e JRA55 exibem MRs de 0.65 e 0.68, respectivamente. O MERRA e NCEP/DOE apresentam MRs mais baixos, sugerindo eventuais restrições na reprodução de padrões mensais. Na escala anual, o ERA5 apresenta um MR de 0.68, destacando sua consistência em estimativas anuais. JRA55 exibe um MR intermediário, contrastando com o GLDAS, MERRA e NCEP (Figura 3). Esses resultados ressaltam a elevância de uma abordagem criteriosa na seleção de modelos de reanálise, considerando a complexidade das variações temporais na Mata Atlântica.




FIGURA 3 Classificação abrangente de modelos (MR) de produtos de reanálise e sensoriamento remoto usados para validar estimativas de velocidade do vento em escalas diária, mensal e anual e para biomas na região Centro-Oeste brasileira, de 2000 a 2020.

5.DISCUSSÕES

A baixa disponibilidade de dados de vento na região Centro-Oeste do Brasil apresenta desafios significativos, destacando a complexidade na representação dos padrões do vento em diferentes escalas. A utilização de dados de satélite, e produtos de reanálises é uma alternativa, mas as disparidades entre essas fontes e os dados do anemômetro *in situ* merecem uma análise mais detalhada (SIEFERT et al., 2021).

A melhor performance da reanálise ERA5 em comparação com outros produtos pode ser atribuída a sua metodologia avançada de assimilação de dados 4D-Var, que incorpora observações ao longo do tempo, o que confere ao ERA5 uma captura superior na representação dos padrões das condições atmosféricas (XU et al., 2022). A resolução espacial e temporal mais fina do ERA5 desempenha um papel crucial ao permitir a captura de detalhes e variações temporais mais sutis nos padrões de vento, resultando em estimativas mais precisas. Possíveis melhorias nos esquemas físicos do modelo, como aprimoramentos na parametrização da camada limite e interação atmosfera-superfície, também contribuem para a qualidade superior das estimativas de vento. Além disso, a eficiente assimilação de dados de satélite, aliada a um ciclo constante de atualizações, validações e melhorias contínuas do modelo, solidificam a robustez do ERA5 em estimar a velocidade do vento na região (HERSBACH et al., 2020).

Quanto às estimativas de velocidade do vento no bioma Pantanal, a reanálise GLDAS teve uma performance superior em comparação com os outros produtos analisados. Este destaque não se limita apenas à sua representação precisa da superfície terrestre e aos algoritmos refinados, mas também à sua capacidade em responder de maneira mais eficiente aos complexos processos do sistema solo-planta-atmosfera no Pantanal, a maior planície alagável do mundo. Além disso, o esquema de parametrização da camada limite atmosférica demonstra uma adaptação mais precisa à complexidade meteorológica única do Pantanal. A consideração apropriada das variações hidrológicas, marcantes nessa região, desempenha um papel crucial na obtenção de uma representação mais autêntica das condições atmosféricas e, por conseguinte, na obtenção de estimativas mais precisas de velocidade do vento.

O desempenho do JRA-55 revela diferenças substanciais em várias regiões e escalas temporais. Essas disparidades se tornam especialmente evidentes em escalas diárias, onde o JRA-55 tende a apresentar superestimação nas velocidades do vento em determinadas áreas. Essa tendência pode ser atribuída a possíveis inadequações nos métodos de parametrização da camada limite atmosférica e nas estratégias de assimilação de dados, uma vez que a modelagem desse produto se baseia amplamente na combinação de dados observados em superfície,

satélites e sondagens (KOBAYASHI et al., 2015). Essas observações destacam a importância crucial de considerar a variabilidade temporal e geográfica ao avaliar o desempenho do JRA-55 na estimativa da velocidade do vento.

As baixas performances observadas no MERRA-2 e NCEP/DOE comparadas a ERA5 e GLDAS suscitam discussões pertinentes sobre diversos fatores que podem influenciar diretamente a qualidade das estimativas de velocidade do vento. A resolução espacial grosseira desses modelos emerge como uma possível limitação, impactando sua capacidade de capturar detalhes finos nos padrões atmosféricos. Esse aspecto é particularmente crítico em regiões complexas como o Centro-Oeste do Brasil, onde a topografia variada e a presença de diferentes biomas demandam uma resolução mais refinada para representar adequadamente as características locais. Além disso, a densidade e qualidade dos dados assimilados, assim como os esquemas de parametrização da camada limite em cada modelo, também desempenham um papel significativo (RAMON et al., 2019).

As velocidades do vento são parametrizadas na camada limite, considerando as características da superfície terrestre e a estabilidade na extrapolação até 10 metros. O uso de diferentes métodos de extrapolação vertical resulta em tendências inconsistentes na reanálise da velocidade do vento (FAN et al., 2021). O ERA5 utiliza o esquema Monin-Obukhov modificado, ajustando o comprimento da rugosidade aerodinâmica de acordo com o arrasto orográfico. No MERRA-2, o esquema de Helfand e Schubert, baseado na teoria de similaridade de Monin-Obukhov, interpola os ventos a 10 metros. O JRA-55, sob a suposição de estabilidade neutra, extrapola a velocidade do vento do modelo de nível mais baixo para 10 metros por meio de um método de interpolação bidimensional univariado ideal (TORRALBA et al., 2017). Importante notar que as velocidades extrapoladas do vento podem ser significativamente reduzidas, especialmente em áreas florestais, devido à elevada posição do nível mais baixo. Essa diversidade de métodos de processamento de dados pode influenciar as tendências e introduzir viés entre os diferentes modelos analisados.

Na região Centro-Oeste do Brasil, a baixa densidade de estações meteorológicas se revela como um obstáculo significativo para o desenvolvimento de modelos climáticos precisos e a implementação eficaz de estratégias adaptativas (JUNIOR et al., 2021). Embora as reanálises possam suprir a carência decorrente da ausência de registros observacionais extensos e de alta qualidade, a limitada presença de estações em superfície se torna um importante fator a levar em consideração. Esta escassez de estações meteorológicas na região não apenas compromete a validação de produtos climáticos, mas também impacta diretamente a

configuração de modelos essenciais para compreender padrões climáticos específicos da área. A falta de dados em tempo real provenientes de estações distribuídas estrategicamente prejudica a precisão e confiabilidade desses modelos, afetando, assim, a capacidade de antecipar eventos climáticos e suas implicações (HARRIS et al., 2020). No entanto, é importante ressaltar que os produtos de reanálises podem ter dificuldades em capturar os ventos da superfície terrestre a partir de observações in situ. O que pode ser explicado em razão da simulação inadequada de terreno não homogêneo e condições da camada limite atmosférica no processo de assimilação de dados (FAN et al., 2021).

Regionalmente, a correlação entre as medições observadas e as reanálises revela um padrão similar. Contudo, ao analisar a variabilidade espaço-temporal, nenhum dos produtos apresentou um desempenho satisfatório na representação da velocidade do vento na região Amazônica. A Amazônia é caracterizada por gradientes de pressão moderados e um alto atrito superficial, derivado da rugosidade da vegetação densa (SIEFERT et al., 2022). Essas condições resultam em baixas velocidades de vento, tanto sazonalmente quanto anualmente, sobre o Brasil, particularmente sobre estações situadas na zona Equatorial (GILLILAND & KEIM, 2018).

De modo geral, os resultados desta comparação entre as reanálises e as estações meteorológicas na região Centro-Oeste do Brasil corroboram com outros estudos que indicam uma performance limitada de diversos conjuntos de reanálises na reprodução nos padrões das velocidades de vento superficiais com base em dados provenientes de diferentes regiões do mundo. Esses estudos abrangem áreas como a China (ZHANG et al., 2019) e EUA (ROSE & APT, 2016). Além disso, Siefert et al (2022) aponta limitações associadas especialmente à resolução espacial em regiões de relevo complexo e às condições microclimáticas de entorno.

Além disso, estratégias como a proposta de fatores de correção com base em dados observados ou métodos empíricos têm demonstrado eficácia notável para aprimorar o desempenho das reanálises ou das simulações derivadas de suas variáveis. Essas abordagens representam avanços substanciais na mitigação das incertezas associadas ao uso de dados de velocidade do vento provenientes de reanálises, contribuindo assim para uma maior confiabilidade e precisão nos resultados obtidos em estudos meteorológicos e climáticos (SIEFERT et al., 2022).

6. CONCLUSÕES

As estimativas de velocidade do vento derivadas de diferentes produtos de reanálise em escalas diárias, mensais e anuais, é possível concluir que há variações significativas na performance desses modelos em diferentes biomas. Os produtos ERA5 e GLDAS se destacaram, mantendo uma consistência notável em suas estimativas, especialmente em escalas diárias e anuais. No entanto, é crucial observar que, mesmo com essa consistência, houve diferenças estatisticamente significativas em algumas instâncias, especialmente nas escalas mensais. Por outro lado, a reanálise MERRA 2 mostrou desempenho inferior em todas as escalas temporais, indicando uma tendência sistemática de subestimação diária e divergências consideráveis nas escalas mensais e anuais, particularmente em alguns biomas como o Pantanal e a Mata Atlântica. Essas discrepâncias sugerem limitações na capacidade do MERRA 2 em reproduzir padrões temporais específicos da velocidade do vento.

Esses resultados ressaltam a importância crítica de uma escolha cuidadosa e uma avaliação rigorosa dos modelos de reanálise ao estudar a velocidade do vento em diferentes biomas. A variabilidade nas estimativas, mesmo nos modelos mais consistentes, destaca a complexidade das interações atmosféricas e a necessidade de considerar a especificidade de cada região ao interpretar os resultados. Este estudo contribui significativamente para o avanço do entendimento sobre a confiabilidade dos modelos de reanálise na representação da velocidade do vento em diferentes escalas temporais e em diversos ecossistemas, fornecendo insights valiosos para futuras pesquisas e aplicações práticas, como previsões climáticas e estudos de impacto ambiental.

7. 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., BOGENA, 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>

CAÑADILLAS, B., FOREMAN, R., STEINFELD, G., ROBINSON, N., 2023. Cumulative Interactions between the Global Blockage and Wake Effects as Observed by an Engineering Model and Large-Eddy Simulations. **Energies** **16**, 2949. <https://doi.org/10.3390/en16072949>

CARVALHO, D., ROCHA, A., GÓMEZ-GESTEIRA, M., ALVAREZ, I., SILVA SANTOS, C., 2013. Comparison between CCMP, QuikSCAT and buoy winds along the Iberian Peninsula coast. **Remote Sensing of Environment** **137**, 173–183. <https://doi.org/10.1016/j.rse.2013.06.005>

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>

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., RANGLES, 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>

GILLILAND, J.M., KEIM, B.D., 2018. Surface wind speed: trend and climatology of Brazil from 1980–2014. **International Journal of Climatology** **38**, 1060–1073. <https://doi.org/10.1002/joc.5237>

HARRIS, I., OSBORN, T.J., JONES, P., LISTER, D., 2020. Version 4 of the CRU TS monthly high-resolution gridded multivariate climate dataset. **Sci Data** **7**, 109. <https://doi.org/10.1038/s41597-020-0453-3>

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. DOS, 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., EBITA, 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>
- PENSIERI, S., BOZZANO, R., SCHIANO, M.E., 2010. Comparison between QuikSCAT and buoy wind data in the Ligurian Sea. **Journal of Marine Systems** 81, 286–296. <https://doi.org/10.1016/j.jmarsys.2010.01.004>
- 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>
- SCHMIDT, K.M., SWART, S., REASON, C., NICHOLSON, S.-A., 2017. Evaluation of Satellite and Reanalysis Wind Products with In Situ Wave Glider Wind Observations in the Southern Ocean. **Journal of Atmospheric and Oceanic Technology** 34, 2551–2568. <https://doi.org/10.1175/JTECH-D-17-0079.1>
- 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>
- TORRALBA, V., DOBLAS-REYES, F.J., GONZALEZ-REVIRIEGO, N., 2017. Uncertainty in recent near-surface wind speed trends: a global reanalysis intercomparison. **Environ. Res. Lett.** 12, 114019. <https://doi.org/10.1088/1748-9326/aa8a58>
- 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>

ZHAI, J., XIAO, C., FENG, Z., LIU, Y., 2023. Are there suitable global datasets for monitoring of land use and land cover in the tropics? Evidences from mainland Southeast Asia. **Global and Planetary Change** **229**, 104233. <https://doi.org/10.1016/j.gloplacha.2023.104233>

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>

8. ANEXOS

TABELA 3 Análise de concordância de produtos de reanálise e sensoriamento remoto utilizados para validar estimativas de velocidade do vento (V) em escalas diária, mensal e anual na região Centro-Oeste brasileira, de 2000 a 2020.

Escala	Produto	Média ± CI (m ⁻¹ s ⁻¹)	r	d	RMSE	MAE	ρ_c	PBIAS
Diária	Measured	1.96 ± 0.02	-	-	-	-	-	-
	ERA5	1.87 ± 0.02	0.47	0.69	0.87	0.67	0.48	5.20
	GLDAS	2.01 ± 0.02	0.45	0.69	0.94	0.73	0.46	15.90
	JRA 55	2.21 ± 0.03	0.39	0.65	1.09	0.85	0.4	25.30
	MERRA 2	4.42 ± 0.05	0.41	0.41	2.90	2.48	0.15	143.80
	NCEP/DOE	2.68 ± 0.03	0.29	0.52	1.77	1.36	0.24	57.30
Mensal	Measured	1.97 ± 0.07	-	-	-	-	-	-
	ERA5	1.88 ± 0.05	0.42	0.60	0.75	0.58	0.36	5.10
	GLDAS	2.01 ± 0.06	0.43	0.63	0.80	0.62	0.37	15.70
	JRA 55	2.21 ± 0.07	0.35	0.58	0.91	0.72	0.29	25.20
	MERRA 2	4.43 ± 0.12	0.37	0.35	2.74	2.45	0.09	143.30
	NCEP/DOE	2.68 ± 0.09	0.27	0.48	1.39	1.11	0.16	57.40
Anual	Measured	1.97 ± 0.21	-	-	-	-	-	-
	ERA5	1.88 ± 0.08	0.45	0.55	0.68	0.53	0.31	4.00
	GLDAS	2.01 ± 0.01	0.40	0.60	0.74	0.58	0.32	14.40
	JRA 55	2.21 ± 0.09	0.36	0.53	0.81	0.66	0.21	23.70
	MERRA 2	4.43 ± 0.20	0.36	0.33	2.64	2.41	0.07	140.00
	NCEP/DOE	2.67 ± 0.13	0.28	0.46	1.26	1.05	0.11	56.10

TABELA 4 Análise de concordância de produtos de reanálise e sensoriamento remoto utilizados para validar estimativas de velocidade do vento (V) para biomas da região Centro-Oeste brasileira, de 2000 a 2020.

Escala	Biomas	Produtos	Média ± CI (m ⁻¹ s ⁻¹)	MAE	RMSE	r	d	ρ_c	PBIAS
Diária	Amazônia	Measured	1.88 ± 0.02	-	-	-	-	-	-
		ERA5	1.85 ± 0.02	0.53	0.69	0.34	0.61	0.36	8.88
		GLDAS	2.01 ± 0.02	0.53	0.7	0.32	0.6	0.34	10.04
		JRA 55	2.17 ± 0.03	0.77	0.99	0.29	0.58	0.29	28.89
		MERRA 2	4.50 ± 0.05	1.31	1.61	0.3	0.48	0.15	50.09
	Cerrado	NCEP/DOE	2.63 ± 0.04	1.2	1.53	0.27	0.52	0.19	44.42
		Measured	1.92 ± 0.03	-	-	-	-	-	-
		ERA5	2.02 ± 0.03	0.69	0.88	0.45	0.68	0.46	2.16

Mensal	Pantanal	GLDAS	2.16 ± 0.03	0.76	0.97	0.42	0.66	0.42	13.45
		JRA 55	2.46 ± 0.04	0.85	1.09	0.36	0.63	0.38	16.83
		MERRA 2	4.44 ± 0.06	2.73	3.1	0.36	0.46	0.12	60.11
		NCEP/DOE	3.29 ± 0.07	1.28	1.67	0.25	0.53	0.22	31.86
		Measured	1.65 ± 0.04	-	-	-	-	-	-
	Mata Atlântica	ERA5	2.45 ± 0.05	0.95	1.31	0.46	0.62	0.36	32.67
		GLDAS	2.28 ± 0.04	0.8	1.03	0.52	0.66	0.43	28.28
		JRA 55	2.49 ± 0.06	1.02	1.33	0.46	0.62	0.37	33.83
		MERRA 2	5.19 ± 0.08	3.53	3.83	0.49	0.42	0.1	68.33
		NCEP/DOE	3.58 ± 0.09	2.06	2.58	0.41	0.52	0.19	53.98
	Amazônia	Measured	1.49 ± 0.03	-	-	-	-	-	-
		ERA5	1.39 ± 0.02	0.68	0.88	0.5	0.67	0.46	3.63
		GLDAS	1.43 ± 0.02	0.79	1.02	0.41	0.64	0.41	13.71
		JRA 55	1.77 ± 0.03	0.9	1.16	0.44	0.65	0.41	22.29
		MERRA 2	2.53 ± 0.03	2.57	2.9	0.38	0.44	0.12	56.89
	Cerrado	NCEP/DOE	2.31 ± 0.04	1.68	2.15	0.36	0.53	0.23	41.79
		Measured	1.89 ± 0.06	-	-	-	-	-	-
		ERA5	1.85 ± 0.05	0.41	0.55	0.27	0.43	0.18	7.63
		GLDAS	2.01 ± 0.06	0.4	0.56	0.29	0.51	0.23	8.85
		JRA 55	2.18 ± 0.07	0.63	0.78	0.23	0.45	0.13	27.64
	Pantanal	MERRA 2	4.51 ± 0.13	1.22	1.44	0.27	0.42	0.08	48.97
		NCEP/DOE	2.63 ± 0.09	1.03	1.2	0.27	0.43	0.1	44.06
		Measured	1.88 ± 0.09	-	-	-	-	-	-
		ERA5	2.00 ± 0.06	0.58	0.73	0.38	0.54	0.3	1.47
GLDAS		2.13 ± 0.08	0.64	0.81	0.36	0.54	0.28	12.71	
Mata Atlântica	JRA 55	2.41 ± 0.09	0.69	0.86	0.27	0.48	0.21	16.31	
	MERRA 2	4.36 ± 0.14	2.67	2.87	0.29	0.35	0.05	59.74	
	NCEP/DOE	3.1 ± 0.16	1	1.26	0.16	0.43	0.1	31.56	
	Measured	1.68 ± 0.12	-	-	-	-	-	-	
	ERA5	2.45 ± 0.11	0.82	1.08	0.24	0.44	0.09	32.21	
Amazônia	GLDAS	2.28 ± 0.08	0.69	0.9	0.29	0.44	0.12	28.76	
	JRA 55	2.49 ± 0.11	0.86	1.06	0.3	0.44	0.12	33.6	
	MERRA 2	5.20 ± 0.15	3.52	3.62	0.32	0.26	0.02	68.28	
	NCEP/DOE	3.61 ± 0.16	1.95	2.11	0.38	0.38	0.06	54.29	
	Measured	1.51 ± 0.16	-	-	-	-	-	-	
Cerrado	ERA5	1.39 ± 0.05	0.56	0.71	0.27	0.4	0.17	1.22	
	GLDAS	1.43 ± 0.04	0.64	0.82	0.16	0.42	0.13	11.85	
	JRA 55	1.77 ± 0.08	0.69	0.89	0.29	0.44	0.18	20.25	
	MERRA 2	2.53 ± 0.08	2.5	2.68	0.09	0.29	0.02	55.75	
	NCEP/DOE	2.31 ± 0.09	1.38	1.59	0.3	0.43	0.12	40.28	
Pantanal	Measured	1.89 ± 0.18	-	-	-	-	-	-	
	ERA5	1.85 ± 0.08	0.38	0.52	0.28	0.33	0.13	7.53	
	GLDAS	2.01 ± 0.12	0.38	0.53	0.26	0.48	0.21	8.76	
	JRA 55	2.18 ± 0.10	0.61	0.73	0.19	0.38	0.09	27.6	
	MERRA 2	4.52 ± 0.21	1.21	1.41	0.25	0.4	0.06	48.94	
Anual		NCEP/DOE	2.64 ± 0.14	1.01	1.14	0.31	0.36	0.07	44.03

	Measured	1.88 ± 0.24	-	-	-	-	-	-
Mata Atlântica	ERA5	2.01 ± 0.07	0.56	0.7	0.38	0.49	0.25	1.2
	GLDAS	2.13 ± 0.20	0.62	0.77	0.34	0.48	0.23	12.35
	JRA 55	2.41 ± 0.16	0.66	0.81	0.27	0.38	0.14	15.98
	MERRA 2	4.36 ± 0.26	2.66	2.82	0.3	0.3	0.04	59.59
	NCEP/DOE	3.19 ± 0.32	0.96	1.18	0.12	0.36	0.06	31.4

3.2 CAPÍTULO 2 – VALIDAÇÃO DE PRODUTOS DE PRECIPITAÇÃO DE SENSORIAMENTO REMOTO E REANÁLISES SOBRE O CENTRO-OESTE DO BRASIL

RESUMO

A precipitação é vital para processos hidrológicos, modelagem climática e atividades agrícolas, mas a obtenção de dados confiáveis, especialmente em regiões como o Centro-Oeste brasileiro, é desafiadora devido à falta de estações meteorológicas. Para superar essa lacuna, métodos avançados de sensoriamento remoto e reanálises climáticas são essenciais. O uso de dados de satélite, como os fornecidos pelo GPCP, GPM, MERRA-2 e TRMM, tem sido valioso para estimativas de precipitação em diversas aplicações. Além disso, as reanálises, como ERA5-Land, GLDAS, CHIRPS e CPC, desempenham um papel crucial na compreensão da dinâmica atmosférica. No entanto, é essencial avaliar e validar esses produtos para determinar sua eficácia na região em questão. Neste estudo, foram avaliadas as estimativas de precipitação fornecidas por diversos produtos em relação aos dados observados na região Centro-Oeste do Brasil, utilizando uma abordagem de média ensemble para melhorar a confiabilidade e precisão das estimativas. Foram realizadas avaliações das estimativas de precipitação diárias, mensais e anuais dos diversos produtos, considerando apenas situações sem lacunas nos dados das estações meteorológicas automáticas. A comparação entre as observações das estações e os produtos de grade foi feita sem reamostragem ou agregação dos dados, preservando a resolução espacial nativa. Para avaliar a concordância entre os dados medidos e estimados, foram calculados índices de correlação de Spearman, concordância de Lin, percentual de viés (PBIAS), entre outros. As médias e intervalos de confiança foram determinados usando a técnica de reamostragem bootstrap, enquanto o erro entre os valores medidos e estimados foi quantificado por meio do erro quadrático médio e do erro médio absoluto. Além disso, uma classificação abrangente dos modelos foi realizada, consolidando várias métricas de desempenho em um único índice, para comparar e avaliar a consistência dos modelos em relação às diferentes opções de classificação. Os resultados da análise indicam que as estimativas diárias, mensais e anuais de precipitação não demonstraram diferenças estatisticamente significativas em comparação com as medições realizadas, embora tendências de superestimação ou subestimação possam estar presentes. Os produtos CHIRPS e TRMM apresentaram as maiores superestimativas na Amazônia, enquanto o GPM se destacou no Pantanal. O Ensemble de modelos demonstrou o menor grau de incerteza e melhor desempenho em todas as escalas temporais, sugerindo sua eficácia para aprimorar a precisão das estimativas de precipitação. O Climate Prediction Center (CPC) se destacou na estimativa diária, enquanto o Ensemble foi superior nas escalas mensal e anual. No entanto, o desempenho variou entre biomas, destacando a necessidade de considerar as particularidades regionais ao interpretar os resultados. A consistência entre as estimativas dos produtos e as medições *in situ* valida sua utilidade em estudos hidrológicos e meteorológicos, contribuindo para uma compreensão mais robusta das condições climáticas na região Centro-Oeste do Brasil.

1. INTRODUÇÃO

A precipitação desempenha um papel fundamental nos processos hidrológicos, na elaboração de modelos climáticos e na atividade agrícola (HUFFMAN et al., 2007; XU, 2021),

apresentando variabilidade tanto espacial quanto temporal (ZHANG et al., 2020). A disponibilidade de dados de precipitação consistentes e com alta resolução espacial e temporal é essencial para o planejamento de diversas atividades socioeconômicas, como agricultura, pecuária, geração de energia e identificação de áreas de risco para desastres hidrológicos (ROZANTE et al., 2018; PRAKASH et al., 2021). No entanto, existem inúmeras dificuldades na obtenção de dados contínuos por período amplo. As medições tradicionais de precipitação por medidores in situ são relativamente escassas e mal distribuídas pela superfície terrestre, especialmente em áreas de difícil acesso e em países em desenvolvimento (ROZANTE et al., 2018; RODRIGUES et al., 2020). Dados de precipitação em regiões extensas são difíceis de adquirir, seja pela falta de pluviômetros instalados na região, seja por falhas nas estações e erros de leitura. No Brasil, devido à grande extensão territorial, muitas vezes a disponibilidade de informações não é suficiente para todas as regiões de interesse (DA SILVA CHARLES et al., 2022).

A disparidade na distribuição das estações meteorológicas no Brasil não é apenas um desafio logístico, mas também um obstáculo significativo para regiões específicas, como o Centro-Oeste (SIEFERT et al., 2022; XAVIER et al., 2016). O Centro-Oeste brasileiro é uma região de grande importância para a economia nacional, sendo reconhecido pela sua significativa produção agropecuária e pela riqueza de seus biomas e paisagens (MELLO et al., 2020). No entanto, a obtenção de dados climáticos confiáveis é um desafio na região em consequência à baixa densidade de estações meteorológicas, o que pode impactar negativamente a produtividade e a economia local. Diante deste cenário, a procura por métodos precisos para a estimativa de variáveis climáticas, como a precipitação, é fundamental para garantir a sustentabilidade e o avanço da região (CARVALHO & SILVA, 2022). A implementação de metodologias avançadas em sensoriamento remoto e reanálises climáticas para obter estimativas precisas de precipitação em diversas altitudes e regiões geográficas é de suma importância (BHUIYAN et al., 2019).

Nos últimos anos, o uso de dados de satélite para estimar a precipitação tem se mostrado uma ferramenta valiosa na meteorologia e na hidrologia, dados como do *Global Precipitation Climatology Centre* (GPCC) que fornece análises de precipitação global; do *Global Precipitation Measurement* (GPM), em que o satélite opera em órbita baixa da Terra, carregando dois instrumentos para medir a precipitação da Terra; dados da *Modern-Era Retrospective analysis for Research and Applications, Version 2* (MERRA-2), produtos de dados de análise retrospectiva (reanálise) que fornecem estimativas globais subdiárias das

condições atmosféricas e da superfície terrestre ao longo de várias décadas; e dados do *Tropical Rainfall Measuring Mission* (TRMM) que fornecem medições críticas de precipitação nas regiões tropicais e subtropicais da Terra. As estimativas de precipitação a partir de satélites têm sido amplamente empregadas para diversas aplicações e regiões (Wei et al., 2022; DE MORAIS & GONÇALVES, 2023; JIANG et al., 2023).

Concomitantemente, as reanálises, ao integrar dados observacionais e informações remotas em modelos globais, desempenham um papel essencial na compreensão da dinâmica atmosférica, sendo cruciais para modelagens climáticas e hidrológicas devido à sua consistência temporal e espacial (HUANG et al., 2020). Estimativas dos produtos ERA5-Land, *Global Land Data Assimilation System* (GLDAS), *Climate Hazards group InfraRed Precipitation with Station data* (CHIRPS), e *Climate Prediction Center* (CPC) também têm sido amplamente utilizados em diversos estudos (MOGES et al., 2022; NADEEM et al., 2022; ZHANG et al., 2022).

Assim, considerando a diversidade de produtos disponíveis e a capacidade de adaptação aos dados observados, e levando em conta as incertezas inerentes a esse processo, a avaliação desses produtos é imprescindível (CHEN et al., 2018). A integração cuidadosa dessas fontes de dados, juntamente com processos de validação rigorosos, é crucial para determinar qual produto pode fornecer as melhores estimativas de precipitação em relação aos dados medidos nessa região. Diante desse contexto, o objetivo deste estudo é avaliar e validar as estimativas de precipitação fornecidas pelos produtos CPC, CHIRPS, GPCP, GPM, TRMM, ERA5-Land, GLDAS e MERRA-2 na região Centro-Oeste do Brasil.

2. MATERIAL E MÉTODOS

2.1 Área de Estudo

A região Centro-Oeste do Brasil, com uma extensão territorial de 1.612.000 km², conforme dados do IBGE em 2019 (Figura 4), está situada no coração da América do Sul e abrange os estados de Mato Grosso (MT), Mato Grosso do Sul (MS), Goiás (GO) e o Distrito Federal (DF). A região apresenta uma grande amplitude térmica, com variações que vão de 15°C a 40°C. Nos meses de outubro a março, as chuvas são intensas, enquanto nos meses de abril a setembro a região é completamente seca (ALVARES et al., 2013). Durante os meses chuvosos, as temperaturas médias variam entre 30°C e 36°C. Por outro lado, na região norte de Mato Grosso o clima é equatorial úmido, influenciado pelo bioma da Amazônia. Nessa área, as chuvas são frequentes, com índices pluviométricos que variam de 2.000 a 3.000 mm anuais,

enquanto na região do Pantanal, o índice é de 1.250 mm. Além disso, cerca de 70% das chuvas ocorrem até março, tornando o inverno bastante seco (LIRA et al., 2022).

As variações climáticas na região resultam em distintas zonas climáticas, tais como Aw (tropical com inverno seco), Am (tropical úmido), Cwa (subtropical com inverno seco e verão quente) e Cfa (subtropical com calor no verão), segundo a classificação de Köppen-Geiger (ALVARES et al., 2013). Esta região brasileira é marcada pela presença dos biomas Cerrado (Savana brasileira) com 56,8%, Amazônia com 30,0%, Pantanal com 9,4% e Mata Atlântica com 3,8%, conforme informações do IBGE em 2019.

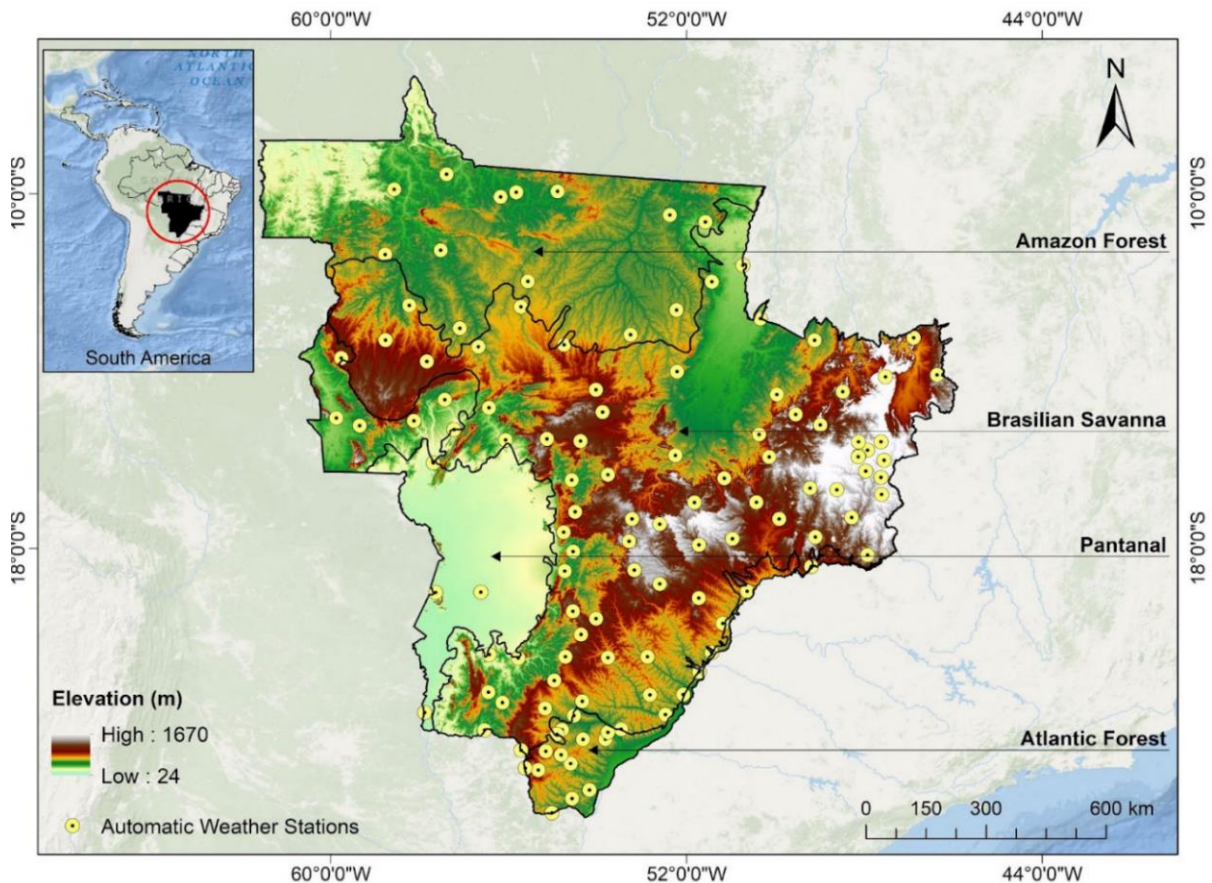


FIGURA 4 - Distribuição espacial das estações meteorológicas automáticas de superfície na região Centro-Oeste do Brasil.

2.2 Observações de Precipitação

As medições de precipitação (Ppt) foram coletadas em 120 estações meteorológicas automáticas de superfície vinculadas ao Instituto Nacional de Meteorologia (INMET), por meio do Banco de Dados Meteorológico para Ensino e Pesquisa (BDMEP), entre os anos 2000 a 2020 (conferir Tabela 1 no anexo) (INMET, 2023). A escolha dessas 120 estações foi fundamentada na consistência e qualidade das séries temporais a longo prazo, visando

minimizar a quantidade de observações ausentes (inferior a 5 a 10%). A presença significativa de dados ausentes pode prejudicar a comparação em escalas mensais e anuais, comprometendo a análise e interpretação dos resultados (Junior et al., 2021). Vale ressaltar que as medições disponíveis inicialmente possuíam uma resolução temporal mais alta (horária). No entanto, optou-se por utilizar resoluções temporais inferiores para adaptar os dados aos produtos de sensoriamento remoto e reanálise.

2.3 Estimativas de Precipitação (Ppt)

Foram utilizadas estimativas de produtos de sensoriamento remoto e reanálise para estimar a precipitação na região Centro-Oeste do Brasil. Estes produtos incluem o *Climate Prediction Center (CPC) Global Unified Gauge-Based Analysis of Daily Precipitation*, *Climate Hazards Group InfraRed Precipitation with Station (CHIRPS)*, *European Centre for Medium-Range Weather Forecasts (ECMWF's – ERA5-LAND)*, *Global Land Data Assimilation System (GLDAS)*, *Global Precipitation Climatology Project (GPCP)*, *Global Precipitation Measurement (GPM)*, *Modern-Era Retrospective Analysis for Research and Applications (MERRA-2)* e *Tropical Rainfall Measurement Mission (TRMM)* (Tabela 5).

Para melhorar a confiabilidade e precisão das estimativas, utilizou-se a técnica de média ensemble, que combina diferentes produtos. Esta abordagem ajuda a minimizar a variabilidade e os erros associados a cada produto individual, aumentando a robustez das estimativas. Optou-se por uma abordagem simples de média aritmética para realizar a combinação, calculando a média dos valores de precipitação de cada produto em cada escala temporal (diária, mensal e anual). A abordagem de média ensemble é amplamente empregada em estudos hidrológicos e meteorológicos para aprimorar a precisão das estimativas e reduzir a incerteza associada aos produtos individuais (BAN et al., 2021).

TABELA 5 Versão, resolução temporal e espacial dos produtos de sensoriamento remoto e reanálises utilizados para validar as estimativas de Precipitação (Ppt) para a região Centro-Oeste do Brasil.

	Produtos	Versão	Resolução Temporal	Resolução Espacial	Referência
Sensoriamento Remoto	GPCP	GPCPDAY 3.1	Diária	0.5° x 0.5°	disc.gsfc.nasa.gov
	GPM	GPM_3IMER GDF v06	Diária	0.1 ° x 0.1 °	disc.gsfc.nasa.gov
	MERRA-2	M2T1NXFLX v5.12.4	Horária	0.5° X 0.625°	disc.gsfc.nasa.gov

Reanálises	TRMM	TRMM_3B42 v7	Diária	0.25° x 0.25°	disc.gsfc.nasa.gov
	ERA5-LAND	ERA5-Land	Horária	0.1° x 0.1°	cds.climate.copernicus.eu
	GLDAS	GLDAS_NO AH025_3H v2.1	3 horas	0.25° x 0.25°	disc.gsfc.nasa.gov
Observações	CHIRPS	CHIRPS v 2.0	Diária	0.05° x 0.05°	chc.ucsb.edu/data/chirps
	CPC Precipitation	-	Diária	0.5° x 0.5°	psl.noaa.gov

2.4 Indicadores de Performance

As estimativas de precipitação diárias, mensais e anuais dos diversos produtos foram avaliadas apenas em situações em que não existiam lacunas de dados nas observações correspondentes das estações meteorológicas automáticas. A localização geográfica de cada estação meteorológica foi combinada com o pixel correspondente (mais próximo do centro de um pixel) dos produtos de grade, isto é, de sensoriamento remoto e reanálise. Para preservar a integridade das estimativas de precipitação em grade, sem alterar seus valores, realizou-se uma comparação direta dos valores ponto a pixel. Portanto, não foi realizada nenhuma reamostragem ou agregação dos dados da grade em termos de resolução espacial, pois isso exigiria a execução de todos os algoritmos de precipitação utilizados para desenvolver esses produtos, o que está fora do escopo desta análise. Assim, a comparação dos dados em grade com os dados da estação foi realizada utilizando sua resolução espacial nativa.

As médias diárias, mensais e anuais dos valores de precipitação (estimativas e medições) foram calculadas juntamente com seus respectivos intervalos de confiança ($\pm 95\%$) utilizando a técnica de reamostragem bootstrap com 1000 interações. O método bootstrap permite estimar amostras aleatórias repetidas para um conjunto de dados do mesmo tamanho da amostra original e o intervalo de confiança indica a confiabilidade da estimativa. Com base nessa abordagem, as médias obtidas em estações próximas diferem significativamente.

A correlação entre os valores de precipitação medidos e estimados foi calculada pelo índice de correlação de Spearman r . Este índice indica a intensidade da relação entre dois conjuntos de dados, variando de -1 até 1. Valores próximos de -1 indicam alta correlação negativa, enquanto valores próximos de 1 indicam alta correlação positiva e valores próximos a zero indicam ausência de correlação (Equação 1).

$$r = 1 - \frac{6 \sum d_i^2}{n^3 - n} \quad (1)$$

Onde, d_i é a diferença entre os postos de cada par de observações e n o tamanho da amostra.

A avaliação da concordância entre os valores medidos e estimados foi realizada utilizando o índice “d”, conforme proposto por Willmott et al. (1985) (Equação 2). Este índice, que varia de 0 a 1, simboliza a ausência de concordância e a concordância perfeita, respectivamente (MACHADO et al., 2015).

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

Onde, P_i é o valor estimado da variável (na escala de tempo diária, mensal ou anual), i representa um numerador para o número de observações de 1 a n (dias, meses ou anos). O_i é o valor da variável medida, e O é a média da variável medida.

A avaliação do grau de erro nas estimativas dos produtos de sensoriamento remoto e reanálise foi realizada com base no Root Mean Squared Error (RMSE), onde se espera que os valores se aproximem de zero (JUNIOR et al., 2021; MACHADO et al., 2015) (Equação 3).

$$RMSE = \sqrt{\frac{\sum (P_i - O_i)^2}{n}} \quad (3)$$

A determinação do erro entre os valores medidos e estimados foi efetuada através do Mean Absolut Error (MAE), onde todas as diferenças individuais possuem o mesmo peso e se espera que os valores sejam próximos de zero (Equação 4).

$$MAE = \frac{\sum |P_i - O_i|}{n} \quad (4)$$

A avaliação da conformidade entre as estimativas e os dados medidos (considerados padrão ouro) foi realizada utilizando o índice de concordância de Lin (ρ_c), conforme expresso na Equação 5. Este índice apresenta uma variação entre -1 e 1, onde o valor de 1 indica uma alta concordância positiva, conforme descrito por Fantin et al., 2018.

$$\rho_c = \frac{2\rho\sigma_x\sigma_y}{2\sigma_x\sigma_y + (\sigma_x - \sigma_y)^2 + (\mu_x - \mu_y)^2} \quad (5)$$

Onde, ρ é o coeficiente de correlação de Pearson, σ_x e σ_y correspondem às variâncias da primeira e segunda séries de medidas e μ_x e μ_y são as médias para as duas séries.

A medida estatística conhecida como Percentual de Viés (PBIAS), introduzida por Gupta et al. (1999), foi empregada para calcular a discrepância entre os valores simulados pelos modelos e os valores observados da série de dados. Esta medida é particularmente útil para determinar se um modelo tem a tendência de subestimar ou superestimar os valores observados ao longo do tempo. Uma correspondência perfeita de 1 para 1 é representada por um PBIAS de 0,0%. Um valor positivo de PBIAS sugere que o modelo tende a superestimar os valores, enquanto um valor negativo indica uma tendência do modelo em subestimar os valores, Equação 6.

$$PBIAS = \frac{\sum(P_i - O_i)^2}{\sum O_i} \times 100 \quad (6)$$

A classificação dos modelos pode ser realizada considerando as pontuações individuais de cada produto, que incluem sensoriamento remoto, reanálise e modelo combinado, utilizando várias métricas de desempenho como r, d, RMSE, MAE, PBIAS e LIN. Adicionalmente, a classificação do modelo abrangente (MR) foi computada para consolidar todas as possíveis classificações, conforme descrito por Avila-Diaz et al. (2020). Esta medida permite a avaliar a consistência de cada modelo frente às diversas opções de classificação (índices e métricas), Equação 7.

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

onde n é o número total de índices, m é o número de modelos e o Rank i 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).

3. RESULTADOS

Os resultados da análise indicam que as estimativas diárias, mensais e anuais de precipitação não demonstraram diferenças estatisticamente significativas em comparação com as medições realizadas. Isso é evidenciado pela sobreposição dos intervalos de confiança de todos os produtos com o intervalo de confiança da precipitação observada (Figura 5). No entanto, é importante notar que, mesmo sem diferenças estatisticamente significativas, podem existir tendências de superestimação ou subestimação nas estimativas diárias de precipitação. Essas tendências, embora sutis o suficiente para não serem estatisticamente significativas, podem ter implicações práticas dependentes do contexto específico em que a precipitação é avaliada.

Ao analisar as estimativas diárias de precipitação, destacou-se que o CHIRPS (15,3%) e o TRMM (14,5%) apresentaram as maiores superestimativas no bioma Amazônia, enquanto o MERRA e o CPC tiveram subestimativas relativamente baixas (1%) (Figura 5). É notável que tenha ocorrido uma diferença estatisticamente significativa entre as estimativas diárias do CHIRPS e as medições correspondentes, indicando menor precisão desse produto no bioma. No Pantanal, o produto GPM foi identificado como o que teve a maior superestimativa na precipitação diária (22,5%), enquanto o MERRA apresentou a maior subestimativa (18,7%) (Figura 5).

As estimativas de precipitação mensal e anual revelaram uma superestimativa, com variações entre os produtos e biomas (Figura 5). O produto GPM destacou-se como aquele que apresentou as maiores superestimativas no Pantanal, enquanto o Ensemble de modelos obteve o menor grau de incerteza em todos os biomas analisados. Esses resultados sublinham a importância de considerar a escala temporal ao avaliar as estimativas de precipitação, uma vez que o desempenho dos produtos pode variar entre diferentes intervalos de tempo.

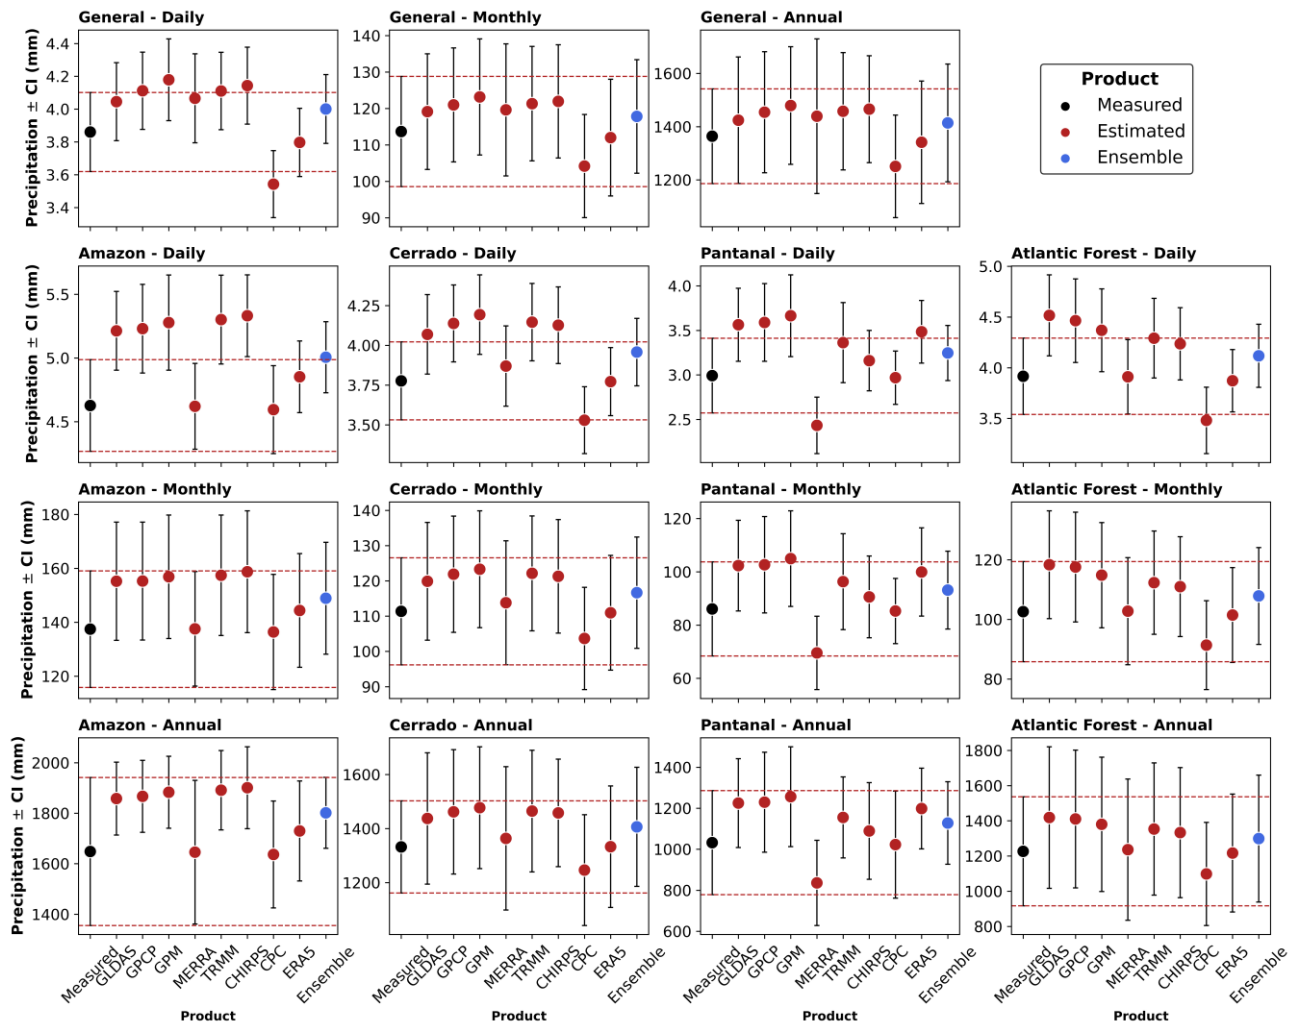


FIGURA 5 Valores médios de precipitação \pm intervalo de confiança (IC) correspondente a escalas diária (mm dia^{-1}), mensal (mm mês^{-1}) e anual (mm ano^{-1}) medido por estações meteorológicas automáticas do INMET e estimado por produtos GLDAS, GPCP, GPM, MERRA, TRMM, CHIRPS, CPC, ERA5-Land e a média multimodelo Ensemble para os biomas da região Centro Oeste, Brasil.

Na análise dos Model Ranks (MR) referentes à capacidade dos produtos em estimar a precipitação diária, destacaram-se o CPC (MR = 0.91) e o Ensemble de modelos (MR = 0.88) como os mais eficientes, enquanto o GPM (MR = 0.64) e o TRMM (MR = 0.58) apresentaram os desempenhos menos satisfatórios (conforme demonstrado na Figura 6). Entretanto, quando voltamos nossa atenção para as estimativas mensais e anuais, o Ensemble (MR = 0.90) e o CPC (MR = 0.67) sobressaíram-se com os resultados mais favoráveis, contrastando com o GPCP e o MERRA, que apresentaram desempenhos mais modestos (MR = 0.48) (Figura 6). Esses achados enfatizam a importância de considerar não apenas a variabilidade espacial e temporal das estimativas de precipitação, mas também as particularidades de cada bioma, ao avaliar o

desempenho desses produtos. Além disso, a menor incerteza e o desempenho superior do Ensemble de modelos em relação aos demais sugerem a vantagem dessa abordagem para aprimorar a precisão das estimativas de precipitação.

No bioma Amazônia, o CPC obteve a mais alta avaliação nas escalas diária, mensal e anual dos Model Ranks (MR), alcançando um MR de 0.95. Em contraste, os desempenhos menos satisfatórios nessas escalas foram observados no TRMM, MERRA e CHIRPS, apresentando MR de 0.67, 0.67 e 0.65, respectivamente (ver Figura 4). No bioma Cerrado, em todas as escalas temporais, o ensemble demonstrou o melhor desempenho (MR = 0.90 a 0.93), enquanto os produtos TRMM (MR = 0.66), MERRA (MR = 0.68) e CPC (MR = 0.66) registraram os desempenhos mais modestos (Figura 6).

No Pantanal, na escala diária, a estimativa de melhor desempenho foi do CPC (MR = 0.95), enquanto nas demais escalas, o ensemble resultou nas melhores estimativas, com MR = 0.92. Em contrapartida, o MERRA apresentou MR inferior em todas as escalas, sugerindo uma menor concordância com os dados medidos. Quanto ao bioma Mata Atlântica, em todas as escalas, o ensemble evidenciou o melhor desempenho (MR = 0.90 e 0.93), enquanto o GLDAS registrou o pior desempenho (MR = 0.66 e 0.67) na avaliação dos Model Ranks (MR), como lustrado na Figura 6.

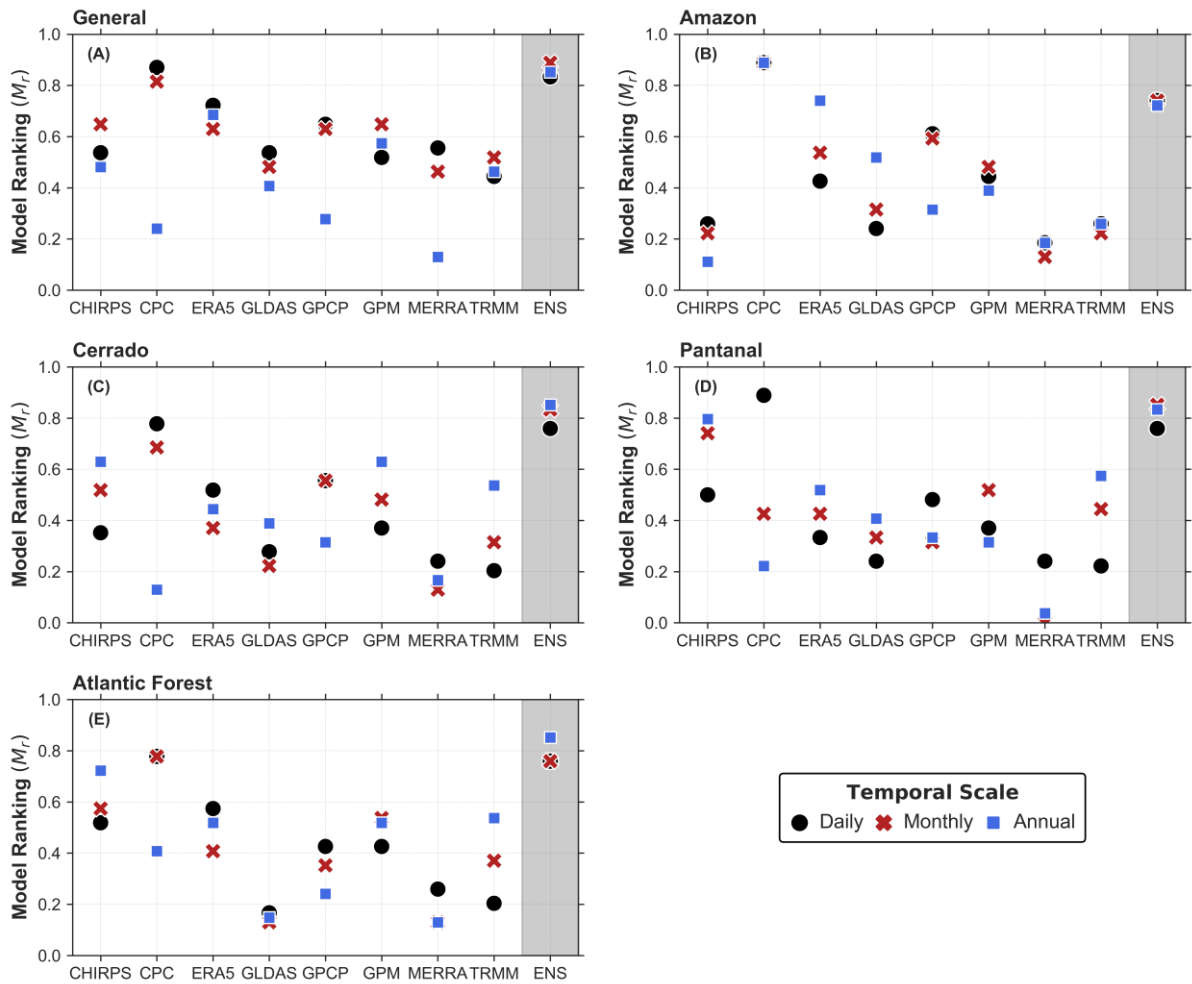


FIGURA 6 Classificação das estimativas de precipitação pelos produtos CHIRPS, CPC, GLDAS, GPCP, GPM, MERRA, TRMM e a média multi-modelo Ensemble utilizando métricas de desempenho (r , d , RMSE, MAE, PBIAS e LIN) correspondente a dados diário (mm dia^{-1}), mensal (mm mês^{-1}) e anual (mm ano^{-1}) (A) e aos biomas Amazônia (B), Cerrado (C), Pantanal (D) e Mata Atlântica (E) da região Centro Oeste, Brasil.

4. DISCUSSÕES

Os resultados apresentados indicam que a capacidade dos produtos em estimar a precipitação varia significativamente dependendo do bioma e da escala temporal considerada. O produto CPC (*Climate Prediction Center*) se destacou na estimativa de precipitação diária, com um Model Rank (MR) de 0.91, e se saiu bem nas escalas mensal e anual, com MR de 0.67. Isso sugere que o CPC é eficaz na captura da variabilidade diária da precipitação, o que pode ser particularmente útil para aplicações que requerem uma resolução temporal fina, como a previsão do tempo. Por outro lado, o Ensemble de modelos, que combina previsões de vários modelos diferentes, apresentou um desempenho superior nas escalas mensal e anual, com um MR de 0.90. Isso indica que a abordagem do Ensemble pode ser mais eficaz para capturar a

variabilidade de longo prazo da precipitação, o que é importante para estudos climáticos e hidrológicos.

No entanto, é importante notar que o desempenho desses produtos varia entre os diferentes biomas. Por exemplo, no bioma Amazônia, o CPC obteve a mais alta avaliação em todas as escalas, enquanto no bioma Cerrado, o Ensemble demonstrou o melhor desempenho. Isso destaca a importância de considerar as particularidades de cada bioma ao avaliar o desempenho desses produtos. Além disso, os resultados sugerem que alguns produtos, como o GPM (*Global Precipitation Measurement*) e o TRMM (*Tropical Rainfall Measuring Mission*), podem ter um desempenho inferior em certas aplicações. Por exemplo, o GPM e o TRMM apresentaram os desempenhos menos satisfatórios na estimativa da precipitação diária, com MRs de 0.64 e 0.58, respectivamente. Em resumo, esses achados enfatizam a importância de considerar a variabilidade espacial e temporal das estimativas de precipitação, bem como as particularidades de cada bioma, ao avaliar o desempenho desses produtos. Além disso, a menor incerteza e o desempenho superior do Ensemble de modelos em relação aos demais sugerem a vantagem dessa abordagem para aprimorar a precisão das estimativas de precipitação.

Nos últimos anos, tem havido um aumento significativo nos estudos que comparam conjuntos de dados climatológicos medidos e estimados (CHEN et al., 2019; JUNIOR et al., 2021; QUANSAH et al., 2022). Este estudo se destaca ao realizar uma avaliação abrangente de diferentes produtos de precipitação para a região Centro-Oeste do Brasil, visando fornecer uma análise mais completa e holística das estimativas climáticas. O que é de grande importância essas informações para a agricultura, os recursos hídricos e o monitoramento ambiental (AGUTU et al., 2017).

O CHIRPS e o TRMM apresentaram as maiores superestimativas de precipitação diária no bioma Amazônico, enquanto o MERRA e o CPC tiveram baixas subestimativas. Essas discrepâncias são atribuídas a várias razões, incluindo diferenças nos algoritmos de processamento, nas fontes de dados e nas abordagens metodológicas adotadas nos diferentes produtos analisados (NADEEM et al., 2022). Sendo que a complexidade da região amazônica, como topografia, vegetação e a presença de rios, apresenta desafios adicionais para as estimativas de precipitação (FASSONI-ANDRADE et al., 2021). Essas características podem dificultar a adequada captura desses padrões climáticos pelos produtos, resultando em superestimativas ou subestimativas.

O produto GPM foi o que teve a maior superestimativa na precipitação diária no Pantanal, enquanto o MERRA apresentou a maior subestimativa. A região do Pantanal é

caracterizada por uma variedade de fatores geográficos e climáticos que podem influenciar a precipitação. Se os produtos GPM e MERRA não levarem em conta adequadamente esses fatores locais, pode haver diferenças nas estimativas de precipitação (GELARO et al., 2017; SKOFRONICK-JACKSON et al., 2017). Nas estimativas mensais e anuais, houve uma superestimativa geral, com variações entre produtos e biomas. Cada produto de estimativa utiliza diferentes métodos, por isso é importante destacar que a qualidade e a disponibilidade das fontes de dados utilizadas por cada produto podem variar, assim como os algoritmos de calibração e correção aplicados a esses dados, que também podem afetar suas estimativas (CHEN et al., 2019).

O Ensemble de modelos obteve o menor grau de incerteza e melhor desempenho em todas as escalas temporais, sugerindo sua vantagem para melhorar a precisão das estimativas de precipitação. A utilização do ensemble foi especialmente benéfica devido à alta variabilidade climática dessas regiões. Ao combinar as estimativas de múltiplos produtos, é possível obter uma visão mais abrangente dos padrões climáticos e reduzir possíveis vieses presentes em cada conjunto de dados individual. O ensemble pode ajudar a mitigar as discrepâncias encontradas nos produtos individuais, resultando em estimativas mais confiáveis e representativas das condições climáticas reais (BAN et al., 2021). Além disso, ao considerar uma variedade de produtos, o ensemble leva em conta as incertezas inerentes às estimativas climáticas, fornecendo uma avaliação mais completa e abrangente (MANZANAS et al., 2019).

A consistência entre as estimativas e as medições *in situ* reforça a confiabilidade desses produtos analisados, sendo válidos para uso em estudos hidrológicos e meteorológicos. Esses conjuntos de dados fornecem uma representação direta das condições climáticas observadas em uma determinada região, o que é fundamental para embasar tomadas de decisão. O uso de conjuntos de dados complementares pode proporcionar uma visão mais abrangente e robusta das condições climáticas, contribuindo para uma melhor compreensão e monitoramento do clima na região (SUN et al., 2018).

5. CONCLUSÃO

Em conclusão, os resultados desta análise enfatizam a complexidade e a variabilidade intrínseca na capacidade dos diferentes produtos de estimativa de precipitação em abordar as características específicas de cada bioma na região Centro-Oeste do Brasil. O destaque do *Climate Prediction Center* (CPC) na estimativa diária e o desempenho superior do Ensemble de modelos em escalas mensais e anuais indicam a importância de escolher cuidadosamente o

produto de acordo com as necessidades específicas da aplicação, considerando a resolução temporal desejada.

A variação nos desempenhos entre biomas, como a superioridade do CPC na Amazônia e do Ensemble no Cerrado, ressalta a necessidade de uma abordagem diferenciada ao avaliar a precisão desses produtos em diferentes contextos geográficos. As discrepâncias observadas, especialmente as superestimativas no bioma Amazônico pelo CHIRPS e TRMM, destacam os desafios adicionais que certas regiões, como a Amazônia, apresentam devido à sua complexidade climática.

A superestimativa generalizada nas estimativas mensais e anuais aponta para a importância de considerar as particularidades de cada produto e bioma ao interpretar os resultados. O contexto regional, com fatores geográficos e climáticos diversos, influencia significativamente as estimativas de precipitação. A compreensão dessas nuances é crucial para evitar interpretações simplistas e garantir a aplicabilidade dos dados na tomada de decisões em setores vitais, como agricultura e gestão de recursos hídricos.

A vantagem do Ensemble de modelos em termos de menor incerteza e melhor desempenho destaca a eficácia dessa abordagem em lidar com a alta variabilidade climática da região Centro-Oeste. A integração de diferentes fontes de dados, considerando suas respectivas incertezas, proporciona uma visão mais abrangente dos padrões climáticos, reduzindo possíveis vieses presentes em conjuntos de dados individuais.

Em última análise, a consistência entre as estimativas dos produtos e as medições *in situ* reforça a confiabilidade desses conjuntos de dados, validando sua utilidade em estudos hidrológicos e meteorológicos. A utilização complementar de diferentes conjuntos de dados contribui para uma compreensão mais robusta das condições climáticas, fornecendo uma base sólida para o monitoramento ambiental e a tomada de decisões informadas na região Centro-Oeste do Brasil.

6.REFERÊNCIAS BIBLIOGRÁFICAS

ABDELMONEIM, H., SOLIMAN, M. R., & MOGHAZY, H. M. (2022). Hydrologic Assessment of the Uncertainty of Six Remote Sensing Precipitation Estimates Driven by a Distributed Hydrologic Model in the Blue Nile Basin. Em T. Sumi, S. A. Kantoush, & M. Saber (Orgs.), *Wadi Flash Floods: Challenges and Advanced Approaches for Disaster Risk Reduction* (p. 225–249). **Springer**. https://doi.org/10.1007/978-981-16-2904-4_8

AGUTU, N. O., AWANGE, J. L., ZERIHUN, A., NDEHEDEHE, C. E., KUHN, M., & FUKUDA, Y. (2017). Assessing multi-satellite remote sensing, reanalysis, and land surface

models' products in characterizing agricultural drought in East Africa. **Remote Sensing of Environment**, 194, 287–302. <https://doi.org/10.1016/j.rse.2017.03.041>

ALESHINA, M. A., SEMENOV, V. A., & CHERNOKULSKY, A. V. (2021). A link between surface air temperature and extreme precipitation over Russia from station and reanalysis data. **Environmental Research Letters**, 16(10), 105004. <https://doi.org/10.1088/1748-9326/ac1cba>

ALMAGRO, A., OLIVEIRA, P. T. S., & BROCCA, L. (2021). Assessment of bottom-up satellite rainfall products on estimating river discharge and hydrologic signatures in Brazilian catchments. **Journal of Hydrology**, 603, 126897. <https://doi.org/10.1016/j.jhydrol.2021.126897>

ALMAZROUI, M., ASHFAQ, M., ISLAM, M. N., RASHID, I. U., KAMIL, S., ABID, M. A., O'BRIEN, E., ISMAIL, M., REBOITA, M. S., SÖRENSON, A. A., ARIAS, P. A., ALVES, L. M., TIPPETT, M. K., SAEED, S., HAARSMA, R., DOBLAS-REYES, F. J., SAEED, F., KUCHARSKI, F., NADEEM, I., ... SYLLA, M. B. (2021). Assessment of CMIP6 Performance and Projected Temperature and Precipitation Changes Over South America. **Earth Systems and Environment**, 5(2), 155–183. <https://doi.org/10.1007/s41748-021-00233-6>

ALVARES, C. A., STAPE, J. L., SENTELHAS, P. C., DE MORAES GONÇALVES, J. L., & SPAROVEK, G. (2013). Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, 711–728. <https://doi.org/10.1127/0941-2948/2013/0507>

ARAGHI, A., MARTINEZ, C. J., OLESEN, J. E., & HOOGENBOOM, G. (2022). Assessment of nine gridded temperature data for modeling of wheat production systems. **Computers and Electronics in Agriculture**, 199, 107189. <https://doi.org/10.1016/j.compag.2022.107189>

ARAÚJO, C. S. P. DE, SILVA, I. A. C. E, IPPOLITO, M., & ALMEIDA, C. D. G. C. de. (2022). Evaluation of air temperature estimated by ERA5-Land reanalysis using surface data in Pernambuco, Brazil. **Environmental Monitoring and Assessment**, 194(5), 381. <https://doi.org/10.1007/s10661-022-10047-2>

AVILA-DIAZ, A., ABRAHÃO, G., JUSTINO, F., TORRES, R., & WILSON, A. (2020). Extreme climate indices in Brazil: Evaluation of downscaled earth system models at high horizontal resolution. **Climate Dynamics**, 54(11), 5065–5088. <https://doi.org/10.1007/s00382-020-05272-9>

BAN, N., CAILLAUD, C., COPPOLA, E., PICHELLI, E., SOBOLOWSKI, S., ADINOLFI, M., AHRENS, B., ALIAS, A., ANDERS, I., BASTIN, S., BELUŠIĆ, D., BERTHOU, S., BRISSON, E., CARDOSO, R. M., CHAN, S. C., CHRISTENSEN, O. B., FERNÁNDEZ, J., FITA, L., FRISIUS, T., ... ZANDER, M. J. (2021). THE FIRST MULTI-model ensemble of regional climate simulations at kilometer-scale resolution, part I: Evaluation of precipitation. **Climate Dynamics**, 57(1), 275–302. <https://doi.org/10.1007/s00382-021-05708-w>

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(11), 2147–2161. <https://doi.org/10.1175/JHM-D-19-0073.1>

CHEN, S., GAN, T. Y., TAN, X., SHAO, D., & ZHU, J. (2019). Assessment of CFSR, ERA-Interim, JRA-55, MERRA-2, NCEP-2 reanalysis data for drought analysis over China. **Climate Dynamics**, 53(1), 737–757. <https://doi.org/10.1007/s00382-018-04611-1>

DA SILVA CHARLES, T., LOPES, T. R., DUARTE, S. N., NASCIMENTO, J. G., DE CARVALHO RICARDO, H., & PACHECO, A. B. (2022). Estimating average annual rainfall by ordinary kriging and TRMM precipitation products in midwestern Brazil. *Journal of South American Earth Sciences*, 118, 103937.

DE MORAES, R. B. F., & GONÇALVES, F. V. (2023). Comparison of the performance of estimated precipitation data via remote sensing in the Midwest Region of Brazil. **Theoretical and Applied Climatology**. <https://doi.org/10.1007/s00704-023-04523-z>

DERIN, Y., ANAGNOSTOU, E., BERNE, A., BORGA, M., BOUDEVILLAIN, B., BUYTAERT, W., CHANG, C.-H., DELRIEU, G., HONG, Y., HSU, Y. C., LAVADO-CASIMIRO, W., MANZ, B., MOGES, S., NIKOLOPOULOS, E. I., SAHLU, D., SALERNO, F., RODRÍGUEZ-SÁNCHEZ, J.-P., VERGARA, H. J., & YILMAZ, K. K. (2016). Multiregional Satellite Precipitation Products Evaluation over Complex Terrain. **Journal of Hydrometeorology**, 17(6), 1817–1836. <https://doi.org/10.1175/JHM-D-15-0197.1>

FASSONI-ANDRADE, A. C., FLEISCHMANN, A. S., PAPA, F., PAIVA, R. C. D. DE, WONGCHUIG, S., MELACK, J. M., MOREIRA, A. A., PARIS, A., RUHOFF, A., BARBOSA, C., MACIEL, D. A., NOVO, E., DURAND, F., FRAPPART, F., AIRES, F., ABRAHÃO, G. M., FERREIRA-FERREIRA, J., ESPINOZA, J. C., LAIPELT, L., ... PELLET, V. (2021). Amazon Hydrology From Space: Scientific Advances and Future Challenges. **Reviews of Geophysics**, 59(4), e2020RG000728. <https://doi.org/10.1029/2020RG000728>

FUNK, C., PETERSON, P., LANDSFELD, M., PEDREROS, D., VERDIN, J., SHUKLA, S., HUSAK, G., ROWLAND, J., HARRISON, L., HOELL, A., & MICHAELSEN, J. (2015). The climate hazards infrared precipitation with stations—A new environmental record for monitoring extremes. **Scientific Data**, 2(1), Artigo 1. <https://doi.org/10.1038/sdata.2015.66>

GELARO, R., MCCARTY, W., SUÁREZ, M. J., TODLING, R., MOLOD, A., TAKACS, L., RANGLES, 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., ... ZHAO, B. (2017). The Modern-Era Retrospective Analysis for Research and Applications, Version 2 (MERRA-2). **Journal of Climate**, 30(14), 5419–5454. <https://doi.org/10.1175/JCLI-D-16-0758.1>

HESSLEROVÁ, P., POKORNÝ, J., HURYNA, H., & HARPER, D. (2019). Wetlands and Forests Regulate Climate via Evapotranspiration. Em S. An & J. T. A. Verhoeven (Orgs.), *Wetlands: Ecosystem Services, Restoration and Wise Use* (p. 63–93). **Springer International Publishing**. https://doi.org/10.1007/978-3-030-14861-4_4

HOBOUCHIAN, M. P., SALIO, P., GARCÍA SKABAR, Y., VILA, D., & GARREAUD, R. (2017). Assessment of satellite precipitation estimates over the slopes of the subtropical Andes. **Atmospheric Research**, 190, 43–54. <https://doi.org/10.1016/j.atmosres.2017.02.006>

HUFFMAN, G. J., BEHRANGI, A., ADLER, R. F., BOLVIN, D. T., NELKIN, E. J., SONG, Y., & WANG, J.-J. (2021). **The Global Precipitation Climatology Project Version 3 Products**. EGU21-8468. <https://doi.org/10.5194/egusphere-egu21-8468>

HUFFMAN, G. J., BOLVIN, D. T., NELKIN, E. J., WOLFF, D. B., ADLER, R. F., GU, G., HONG, Y., BOWMAN, K. P., & STOCKER, E. F. (2007). The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-Global, Multiyear, Combined-Sensor Precipitation

- Estimates at Fine Scales. **Journal of Hydrometeorology**, 8(1), 38–55. <https://doi.org/10.1175/JHM560.1>
- JIANG, S. H., WEI, L. Y., REN, L. L., ZHANG, L. Q., WANG, M. H., & CUI, H. (2023). Evaluation of IMERG, TMPA, ERA5, and CPC precipitation products over mainland China: Spatiotemporal patterns and extremes. *Water Science and Engineering*, 16(1), 45-56.
- JUNIOR, A. L. P., BIUDES, M. S., MACHADO, N. G., VOURLITIS, G. L., GELI, H. M. E., SANTOS, L. O. F. DOS, 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(3), Artigo 3. <https://doi.org/10.3390/w13030333>
- KOBAYASHI, S., OTA, Y., HARADA, Y., EBITA, A., MORIYA, M., ONODA, H., ONOGI, K., KAMAHORI, H., KOBAYASHI, C., ENDO, H., MIYAOKA, K., & TAKAHASHI, K. (2015). THE JRA-55 REANALYSIS: General Specifications and Basic Characteristics. *気象集誌. 第2輯*, 93(1), 5–48. <https://doi.org/10.2151/jmsj.2015-001>
- LIEBMANN, B., & MECHOSO, C. R. (2011). The south american monsoon system. Em *The Global Monsoon System: Vol. Volume 5* (p. 137–157). **WORLD SCIENTIFIC**. https://doi.org/10.1142/9789814343411_0009
- LIRA, B. R. P., FERNANDES, L. L., & ISHIHARA, J. H. (2022). Pluviometric behavior and trends in the Legal Amazon from 1986 to 2015. **Theoretical and Applied Climatology**, 150(3), 1353–1367. <https://doi.org/10.1007/s00704-022-04200-7>
- LIU, L., GU, H., XIE, J., & XU, Y.-P. (2021). How well do the ERA-Interim, ERA-5, GLDAS-2.1 and NCEP-R2 reanalysis datasets represent daily air temperature over the Tibetan Plateau? **International Journal of Climatology**, 41(2), 1484–1505. <https://doi.org/10.1002/joc.6867>
- MACHADO, N. G., BIUDES, M. S., QUERINO, C. A. S., DANELICHEN, V. H. DE M., & VELASQUE, M. C. S. (2015). Seasonal and interannual pattern of meteorological variables in Cuiabá, Mato Grosso state, **Brazil**. *Revista Brasileira de Geofísica*, 33(3), 477–488. <https://doi.org/10.22564/rbgf.v33i3.748>
- MANZANAS, R., GUTIÉRREZ, J. M., BHEND, J., HEMRI, S., DOBLAS-REYES, F. J., TORRALBA, V., PENABAD, E., & BROOKSHAW, A. (2019). Bias adjustment and ensemble recalibration methods for seasonal forecasting: A comprehensive intercomparison using the C3S dataset. **Climate Dynamics**, 53(3), 1287–1305. <https://doi.org/10.1007/s00382-019-04640-4>
- MELLO, K. DE, TANIWAKI, R. H., PAULA, F. R. DE, VALENTE, R. A., RANDHIR, T. O., MACEDO, D. R., LEAL, C. G., RODRIGUES, C. B., & HUGHES, R. M. (2020). Multiscale land use impacts on water quality: Assessment, planning, and future perspectives in Brazil. **Journal of Environmental Management**, 270, 110879. <https://doi.org/10.1016/j.jenvman.2020.110879>
- MORICE, C. P., KENNEDY, J. J., RAYNER, N. A., WINN, J. P., HOGAN, E., KILLICK, R. E., DUNN, R. J. H., OSBORN, T. J., JONES, P. D., & SIMPSON, I. R. (2021). An Updated Assessment of Near-Surface Temperature Change From 1850: The HadCRUT5 Data Set. **Journal of Geophysical Research: Atmospheres**, 126(3), e2019JD032361. <https://doi.org/10.1029/2019JD032361>

MOGES, D. M., KMOCH, A., & UUEMAA, E. (2022). Application of satellite and reanalysis precipitation products for hydrological modeling in the data-scarce Porijõgi catchment, Estonia. *Journal of Hydrology: Regional Studies*, *41*, 101070.

MUÑOZ-SABATER, J., DUTRA, E., AGUSTÍ-PANAREDA, A., ALBERGEL, C., ARDUINI, G., BALSAMO, G., BOUSSETTA, S., CHOULGA, M., HARRIGAN, S., HERSBACH, H., MARTENS, B., MIRALLES, D. G., PILES, M., RODRÍGUEZ-FERNÁNDEZ, N. J., ZSOTER, E., BUONTEMPO, C., & THÉPAUT, J.-N. (2021). ERA5-Land: A state-of-the-art global reanalysis dataset for land applications. *Earth System Science Data*, *13*(9), 4349–4383. <https://doi.org/10.5194/essd-13-4349-2021>

NADEEM, M. U., GHANIM, A. A. J., ANJUM, M. N., SHANGGUAN, D., RASOOL, G., IRFAN, M., NIAZI, U. M., & HASSAN, S. (2022). Multiscale Ground Validation of Satellite and Reanalysis Precipitation Products over Diverse Climatic and Topographic Conditions. *Remote Sensing*, *14*(18), Artigo 18. <https://doi.org/10.3390/rs14184680>

PENG, X., SHE, J., ZHANG, S., TAN, J., & LI, Y. (2019). Evaluation of Multi-Reanalysis Solar Radiation Products Using Global Surface Observations. *Atmosphere*, *10*(2), Artigo 2. <https://doi.org/10.3390/atmos10020042>

PRAKASH, S., & SRINIVASAN, J. (2021). A comprehensive evaluation of near-real-time and research products of IMERG precipitation over India for the southwest monsoon period. *Remote Sensing*, *13*(18), 3676.

QUANSAH, A. D., DOGBEY, F., ASILEVI, P. J., BOAKYE, P., DARKWAH, L., ODURO-KWARTENG, S., SOKAMA-NEUYAM, Y. A., & MENSAH, P. (2022). Assessment of solar radiation resource from the NASA-POWER reanalysis products for tropical climates in Ghana towards clean energy application. *Scientific Reports*, *12*(1), Artigo 1. <https://doi.org/10.1038/s41598-022-14126-9>

RANDLES, C. A., SILVA, A. M. DA, BUCHARD, V., COLARCO, P. R., DARMENOV, A., GOVINDARAJU, R., SMIRNOV, A., HOLBEN, B., FERRARE, R., HAIR, J., SHINOZUKA, Y., & FLYNN, C. J. (2017). The MERRA-2 Aerosol Reanalysis, 1980 Onward. Part I: System Description and Data Assimilation Evaluation. *Journal of Climate*, *30*(17), 6823–6850. <https://doi.org/10.1175/JCLI-D-16-0609.1>

RODRIGUES, DT, GONÇALVES, WA, SPYRIDES, MH, SANTOS E SILVA, CM, & DE SOUZA, DO (2020). Distribuição espacial do nível de retorno de eventos extremos de precipitação no Nordeste do Brasil. *Revista Internacional de Climatologia*, *40* (12), 5098-5113.

ROZANTE, J. R., VILA, D. A., BARBOZA CHIQUETTO, J., FERNANDES, A. D. A., & SOUZA ALVIM, D. (2018). Evaluation of TRMM/GPM blended daily products over Brazil. *Remote Sensing*, *10*(6), 882.

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>

SALEHIE, O., ISMAIL, T. BIN, SHAHID, S., SAMMEN, S. S., MALIK, A., & WANG, X. (2022). Selection of the gridded temperature dataset for assessment of thermal bioclimatic

environmental changes in Amu Darya River basin. **Stochastic Environmental Research and Risk Assessment**, 36(9), 2919–2939. <https://doi.org/10.1007/s00477-022-02172-8>

SKOFRONICK-JACKSON, G., PETERSEN, W. A., BERG, W., KIDD, C., STOCKER, E. F., KIRSCHBAUM, D. B., KAKAR, R., BRAUN, S. A., HUFFMAN, G. J., IGUCHI, T., KIRSTETTER, P. E., KUMMEROW, C., MENEGHINI, R., OKI, R., OLSON, W. S., TAKAYABU, Y. N., FURUKAWA, K., & WILHEIT, T. (2017). The Global Precipitation Measurement (GPM) Mission for Science and Society. **Bulletin of the American Meteorological Society**, 98(8), 1679–1695. <https://doi.org/10.1175/BAMS-D-15-00306.1>

SUN, Q., MIAO, C., DUAN, Q., ASHOURI, H., SOROOSHIAN, S., & HSU, K.-L. (2018). A Review of Global Precipitation Data Sets: Data Sources, Estimation, and Intercomparisons. **Reviews of Geophysics**, 56(1), 79–107. <https://doi.org/10.1002/2017RG000574>

TAN, M. L., & DUAN, Z. (2017). Assessment of GPM and TRMM Precipitation Products over Singapore. **Remote Sensing**, 9(7), Artigo 7. <https://doi.org/10.3390/rs9070720>

TAREK, M., BRISSETTE, F. P., & ARSENAULT, R. (2020). Evaluation of the ERA5 reanalysis as a potential reference dataset for hydrological modelling over North America. **Hydrology and Earth System Sciences**, 24(5), 2527–2544. <https://doi.org/10.5194/hess-24-2527-2020>

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>

XU, C. Y. (2021). Issues influencing accuracy of hydrological modeling in a changing environment. *Water Science and Engineering*, 14(2), 167–170.

XU, J., MA, Z., YAN, S., & PENG, J. (2022). Do ERA5 and ERA5-Land precipitation estimates outperform satellite-based precipitation products? A comprehensive comparison between state-of-the-art model-based and satellite-based precipitation products over mainland China. **Journal of Hydrology**, 605, 127353. <https://doi.org/10.1016/j.jhydrol.2021.127353>

WEI, L., JIANG, S., REN, L., ZHANG, L., WANG, M., LIU, Y., & DUAN, Z. (2022). Bias correction of GPM IMERG Early Run daily precipitation product using near real-time CPC global measurements. *Atmospheric Research*, 279, 106403.

ZHANG, L., REN, D., NAN, Z., WANG, W., ZHAO, Y., ZHAO, Y., ... & WU, X. (2020). Interpolated or satellite-based precipitation? Implications for hydrological modeling in a meso-scale mountainous watershed on the Qinghai-Tibet Plateau. *Journal of Hydrology*, 583, 124629.

ZHANG, L., CHEN, X., LAI, R., & ZHU, Z. (2022). Performance of satellite-based and reanalysis precipitation products under multi-temporal scales and extreme weather in mainland China. *Journal of Hydrology*, 605, 127389.

7. ANEXOS

TABELA 6 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da precipitação (Ppt) nas escalas diária, mensal e anual pelos produtos CHIRPS, CPC, GLDAS, GPCP, GPM, MERRA-2, TRMM e ensemble para a região Centro-Oeste do Brasil.

Escala	Produto	Média \pm IC ($^{\circ}$ C)	MAE	RMSE	d	r	ρ_c	Pbias
Diária	Medido	3.86 \pm 0.24	-	-	-	-	-	-
	ERA5-LAND	3.79 \pm 0.20	4.54	9.99	0.57	0.59	0.36	4.34
	CHIRPS	4.14 \pm 0.23	4.72	10.19	0.63	0.47	0.42	10.74
	CPC	3.54 \pm 0.21	2.64	7.6	0.81	0.75	0.67	-8
	GLDAS	4.04 \pm 0.23	4.9	10.63	0.59	0.51	0.36	10.57
	GPCP	4.12 \pm 0.24	4.48	10.16	0.66	0.57	0.46	10.79
	GPM	4.18 \pm 0.25	4.57	10.72	0.65	0.56	0.45	11.44
	MERRA	4.06 \pm 0.27	5.02	12.88	0.44	0.58	0.25	5.31
	TRMM	4.12 \pm 0.24	4.86	11.17	0.6	0.5	0.38	10.83
	ENSEMBLE	4.03 \pm 0.21	4.02	8.68	0.7	0.64	0.52	7.8
Mensal	Medido	116.20 \pm 22.97	-	-	-	-	-	-
	ERA5-LAND	112.00 \pm 15.99	39.37	55.98	0.86	0.78	0.75	4.34
	CHIRPS	124.95 \pm 24.32	39.5	65.09	0.91	0.88	0.83	10.74
	CPC	106.56 \pm 21.36	33.44	60.13	0.91	0.86	0.84	-8
	GLDAS	121.47 \pm 24.85	40.51	64.02	0.91	0.87	0.83	10.57
	GPCP	123.46 \pm 24.63	41.42	66.93	0.9	0.87	0.82	10.79
	GPM	125.85 \pm 25.11	38.51	63.22	0.91	0.88	0.84	11.44
	MERRA	121.99 \pm 27.49	53.09	86.26	0.85	0.83	0.72	5.31
	TRMM	123.61 \pm 24.56	38.88	63.85	0.91	0.88	0.83	10.83
	ENSEMBLE	121.41 \pm 24.41	34.25	56.46	0.93	0.89	0.86	7.8
Anual	Medido	1363.98 \pm 177.84	-	-	-	-	-	-
	ERA5-LAND	1341.32 \pm 229.97	213.5	314.23	0.89	0.8	0.8	4.34
	CHIRPS	1464.68 \pm 200.68	217.5	327.33	0.89	0.82	0.79	10.74
	CPC	1250.45 \pm 192.46	216.7	355.18	0.86	0.77	0.74	-8
	GLDAS	1429.89 \pm 237.26	225.4	330.34	0.89	0.81	0.79	10.57
	GPCP	1450.99 \pm 227.17	228.3	334.92	0.89	0.8	0.78	10.79
	GPM	1478.17 \pm 220.69	214.1	323.64	0.89	0.83	0.8	11.44
	MERRA	1436.77 \pm 220.09	289.4	400.85	0.85	0.74	0.72	5.31
	TRMM	1436.77 \pm 290.09	215.4	328.52	0.89	0.82	0.79	10.83
	ENSEMBLE	1423.22 \pm 221.30	185.9	293.53	0.91	0.84	0.82	7.8

TABELA 7 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da precipitação (Ppt) para os biomas da região Centro-Oeste do Brasil.

Escala	Bioma	Produtos	Média \pm IC ($^{\circ}$ C)	MAE	RMSE	d	r	ρ_c	Pbias
Diária	Amazônia	Medido	4.62 \pm 0.36	-	-	-	-	-	-
		ERA5-LAND	4.85 \pm 0.28	5.47	10.97	0.55	0.57	0.32	9.73
		CHIRPS	5.33 \pm 0.32	5.63	11.19	0.62	0.46	0.39	15.5
		CPC	4.59 \pm 0.34	3.31	9.02	0.77	0.73	0.62	-1.31
		GLDAS	5.21 \pm 0.31	5.71	11.32	0.57	0.5	0.34	12.14
		GPCP	5.23 \pm 0.33	5.14	10.78	0.66	0.56	0.46	11.49
		GPM	5.88 \pm 0.37	5.29	11.64	0.65	0.56	0.44	12.46
		MERRA	4.61 \pm 0.33	5.84	13.5	0.42	0.55	0.22	6.75
		TRMM	5.29 \pm 0.35	5.59	11.87	0.61	0.5	0.39	13.37
		ENS	5.02 \pm 0.28	4.73	9.4	0.69	0.62	0.5	10.34
	Cerrado	Medido	3.77 \pm 0.24	-	-	-	-	-	-
		ERA5-LAND	3.77 \pm 0.21	3.94	9.76	0.57	0.6	0.36	2.89
		CHIRPS	4.06 \pm 0.24	4.55	9.97	0.63	0.48	0.41	9.69
		CPC	3.52 \pm 0.21	2.57	7.38	0.81	0.75	0.67	-9.86
		GLDAS	4.06 \pm 0.24	4.71	10.36	0.58	0.52	0.36	8.86
		GPCP	4.13 \pm 0.24	4.31	9.84	0.66	0.58	0.46	9.71
		GPM	4.18 \pm 0.25	4.4	10.4	0.65	0.58	0.45	10.71
		MERRA	3.87 \pm 0.25	4.89	12.86	0.44	0.6	0.25	6.34
		TRMM	4.14 \pm 0.24	4.7	10.89	0.59	0.51	0.38	9.96
		ENS	3.97 \pm 0.21	3.88	8.49	0.7	0.64	0.52	6.92
	Pantanal	Medido	2.99 \pm 0.42	-	-	-	-	-	-
		ERA5-LAND	3.16 \pm 0.33	3.94	9.44	0.58	0.48	0.38	15.39
		CHIRPS	3.48 \pm 0.35	3.73	9.03	0.63	0.39	0.43	6.86
		CPC	2.97 \pm 0.29	2.63	7.39	0.77	0.54	0.61	1.92
		GLDAS	3.56 \pm 0.41	4.07	9.86	0.62	0.39	0.4	17.84
		GPCP	3.58 \pm 0.44	3.78	9.85	0.69	0.44	0.5	18.54
		GPM	3.66 \pm 0.46	3.92	10.3	0.67	0.44	0.48	20.16
		MERRA	2.43 \pm 0.32	3.65	10.46	0.43	0.49	0.25	-20.22
		TRMM	3.35 \pm 0.44	4.02	10.74	0.6	0.39	0.4	13.54
		ENS	3.21 \pm 0.31	3.31	7.87	0.72	0.52	0.54	10.01
	Mata Atlântica	Medido	3.90 \pm 0.38	-	-	-	-	-	-
		ERA5-LAND	3.87 \pm 0.30	4.39	9.97	0.61	0.56	0.41	-0.85
		CHIRPS	4.23 \pm 0.36	4.59	10.17	0.67	0.44	0.46	8.56
		CPC	3.48 \pm 0.32	2.12	6.5	0.87	0.79	0.77	-13.06
		GLDAS	4.51 \pm 0.40	5.01	11.23	0.62	0.46	0.4	14.74
		GPCP	4.46 \pm 0.42	4.68	11	0.66	0.5	0.46	13.24
GPM		4.37 \pm 0.41	4.66	11.16	0.66	0.5	0.45	11.3	
MERRA		3.91 \pm 0.36	4.91	12.72	0.49	0.55	0.29	1.85	

		TRMM	4.29 ± 0.40	4.95	11.77	0.61	0.44	0.4	10.4	
		ENS	4.14 ± 0.32	3.97	8.82	0.73	0.62	0.55	7.48	
	Amazônia	Medido	138.59 ± 31.12							
		ERA5-LAND	144.37 ± 21.08	45.21	66.58	0.86	0.77	0.75	9.73	
		CHIRPS	159.05 ± 34.35	44.66	80.47	0.9	0.88	0.81	15.5	
		CPC	137.23 ± 31.16	32.58	63.42	0.93	0.89	0.87	-1.31	
		GLDAS	155.47 ± 33.64	41.72	72.85	0.91	0.88	0.83	12.14	
		GPCP	156.37 ± 33.51	44.09	77.29	0.9	0.87	0.82	11.49	
		GPM	157.93 ± 33.88	41.99	74.92	0.91	0.88	0.83	12.46	
		MERRA	138.03 ± 30.89	51.83	87.98	0.87	0.85	0.76	6.75	
		TRMM	158.61 ± 34.66	42.96	76.3	0.91	0.87	0.83	13.37	
		ENS	149.69 ± 32.15	36.89	66.8	0.93	0.89	0.86	10.34	
	Cerrado	Medido	113.36 ± 23.38	-	-	-	-	-	-	
		ERA5-LAND	110.94 ± 16.28	37.37	54.63	0.87	0.8	0.76	2.89	
		CHIRPS	123.79 ± 25.28	32.62	57	0.93	0.91	0.86	9.69	
		CPC	105.95 ± 22.31	28.92	55.88	0.92	0.9	0.85	-9.86	
		GLDAS	122.45 ± 25.70	33.83	57.2	0.92	0.91	0.85	8.86	
		GPCP	124.43 ± 25.63	34.26	59.34	0.92	0.91	0.85	9.71	
		GPM	126.32 ± 25.87	32.03	56.22	0.93	0.92	0.87	10.71	
		MERRA	116.08 ± 26.55	45.78	81.05	0.86	0.89	0.75	6.34	
		TRMM	124.15 ± 25.65	32.19	56.44	0.93	0.92	0.86	9.96	
		ENS	119.62 ± 24.79	28.68	50.46	0.94	0.93	0.89	6.92	
Mensal	Pantanal	Medido	90.36 ± 22.78	-	-	-	-	-	-	
		ERA5-LAND	99.93 ± 16.56	34.11	47.36	0.84	0.75	0.71	15.39	
		CHIRPS	94.68 ± 21.35	25.71	44.58	0.91	0.89	0.83	6.86	
		CPC	89.44 ± 15.37	31.75	56.32	0.84	0.81	0.7	1.92	
		GLDAS	107.23 ± 23.85	30.32	48.31	0.9	0.89	0.82	17.84	
		GPCP	107.71 ± 25.49	32.47	53.39	0.89	0.89	0.8	18.54	
		GPM	110.30 ± 25.25	27.9	45.23	0.92	0.91	0.85	20.16	
		MERRA	73.21 ± 18.59	36.23	58.55	0.81	0.85	0.67	-20.22	
		TRMM	101.01 ± 24.59	27.69	47.15	0.91	0.89	0.83	13.54	
		ENS	96.72 ± 21.00	24.48	38.61	0.93	0.91	0.87	10.01	
		Mata Atlântica	Medido	115.21 ± 22.24	-	-	-	-	-	-
			ERA5-LAND	101.46 ± 15.90	37.46	52.47	0.86	0.78	0.74	-0.85
			CHIRPS	124.85 ± 22.08	33.51	51.5	0.92	0.89	0.84	8.56
			CPC	102.47 ± 19.46	25.77	45.99	0.93	0.91	0.86	-13.06
			GLDAS	132.98 ± 24.45	37.25	56.38	0.91	0.88	0.83	14.74
			GPCP	132.01 ± 24.40	37.25	58.43	0.91	0.88	0.82	13.24
			GPM	128.66 ± 23.67	32.87	51.62	0.92	0.9	0.86	11.3
			MERRA	115.26 ± 25.02	46.23	73.74	0.84	0.83	0.71	1.85
			TRMM	126.45 ± 23.15	33.27	52.36	0.92	0.89	0.85	10.4
			ENS	122.00 ± 22.34	28.98	45.35	0.94	0.91	0.88	7.48
Anual	Amazônia	Medido	1651.844 ± 293.20	-	-	-	-	-	-	

	ERA5-LAND	1729.81 ± 197.95	259.62	412.15	0.88	0.81	0.78	9.73
	CHIRPS	1903.34 ± 162.33	322.28	482.8	0.85	0.77	0.73	15.5
	CPC	1636.82 ± 212.11	232.7	389.45	0.89	0.82	0.79	-1.31
	GLDAS	1858.75 ± 144.61	280.8	448.54	0.87	0.79	0.75	12.14
	GPCP	1866.12 ± 142.62	290.96	456.05	0.86	0.76	0.74	11.49
	GPM	1885.77 ± 142.58	280.83	455.1	0.86	0.78	0.74	12.46
	MERRA	1648.35 ± 284.55	310.35	471.07	0.85	0.75	0.72	6.75
	TRMM	1889.65 ± 157.37	289.33	468.9	0.86	0.77	0.73	13.37
	ENS	1812.43 ± 143.37	242.84	419.34	0.88	0.81	0.77	10.34
	Medido	1333.89 ± 170.36	-	-	-	-	-	-
Cerrado	ERA5-LAND	1332.82 ± 224.63	203.54	294.18	0.9	0.79	0.81	2.89
	CHIRPS	1434.40 ± 242.62	198.4	289.96	0.91	0.82	0.82	9.69
	CPC	1246.56 ± 204.75	215.36	357.18	0.85	0.75	0.72	-9.86
	GLDAS	1434.40 ± 242.62	207.82	295.9	0.9	0.8	0.81	8.86
	GPCP	1464.06 ± 229.81	211.57	303.03	0.9	0.8	0.81	9.71
	GPM	1481.98 ± 225.26	196.15	289.29	0.91	0.83	0.83	10.71
	MERRA	1367.67 ± 264.93	290.76	395.7	0.85	0.72	0.72	6.34
	TRMM	1465.11 ± 224.92	199.07	293.11	0.91	0.82	0.82	9.96
	ENS	1414.21 ± 220.78	174.63	264.17	0.92	0.84	0.85	6.92
		Medido	1033.05 ± 253.45	-	-	-	-	-
Pantanal	ERA5-LAND	1198.55 ± 196.47	194.65	245.23	0.9	0.89	0.81	15.39
	CHIRPS	1084.63 ± 235.43	128.63	199.72	0.92	0.9	0.86	6.86
	CPC	1023.58 ± 260.71	206.58	320.1	0.83	0.74	0.7	1.92
	GLDAS	1224.46 ± 216.68	190.73	255.21	0.89	0.89	0.8	17.84
	GPCP	1233.18 ± 243.84	200.13	265.17	0.89	0.89	0.8	18.54
	GPM	1259.20 ± 243.30	218.42	270.82	0.89	0.9	0.8	20.16
	MERRA	837.20 ± 207.63	239.36	299.19	0.81	0.75	0.67	-20.22
	TRMM	1157.42 ± 197.50	179.16	238.75	0.9	0.87	0.82	13.54
	ENS	1119.19 ± 206.45	144.33	195.78	0.93	0.92	0.87	10.01
		Medido	1233.84 ± 309.73	-	-	-	-	-
Mata Atlântica	ERA5-LAND	1216.61 ± 335.19	181.39	245.71	0.91	0.79	0.83	-0.85
	CHIRPS	1429.45 ± 402.20	169.45	234.11	0.92	0.86	0.85	8.56
	CPC	1090.95 ± 293.09	178.21	269.5	0.89	0.86	0.8	-13.06
	GLDAS	1429.45 ± 402.20	225.34	303.52	0.89	0.84	0.79	14.74
	GPCP	1403.73 ± 391.64	210.25	285.52	0.9	0.83	0.81	13.24
	GPM	1376.162 ± 381.59	187.32	255.67	0.92	0.85	0.84	11.3
	MERRA	1230.38 ± 401.23	233.35	309.24	0.87	0.74	0.76	1.85
	TRMM	1345.801 ± 375.82	182.27	255.87	0.92	0.85	0.84	10.4
	ENS	1319.95 ± 365.37	154.66	217.9	0.93	0.88	0.87	7.48

3.3 CAPÍTULO 3 – VALIDAÇÃO DE REANÁLISES DE TEMPERATURA DO AR, UMIDADE RELATIVA DO AR E DÉFICIT DE PRESSÃO DE VAPOR PARA O CENTRO-OESTE BRASILEIRO

RESUMO

O clima na região apresenta notáveis gradientes de temperatura e precipitação, resultando em diversas zonas climáticas. No entanto, a escassez de estações meteorológicas representa um desafio para a obtenção de dados climáticos precisos, especialmente em áreas remotas e de difícil acesso. Para preencher essa lacuna, o estudo utiliza produtos de reanálise para estimar variáveis climáticas como temperatura do ar, umidade relativa e déficit de pressão de vapor. Esses produtos são combinados usando a técnica de média ensemble para melhorar a precisão das estimativas. A avaliação do desempenho dessas estimativas é realizada utilizando diversas métricas estatísticas, incluindo correlação de Spearman, índice de concordância de Lin, erro quadrático médio, percentual de viés e métrica de classificação do modelo abrangente. Os resultados são fundamentais para compreender a confiabilidade das estimativas e sua utilidade para estudos climáticos na região Centro-Oeste do Brasil. Foram avaliadas as estimativas de temperatura do ar máxima (Tarmáx), média (Tarméd), mínima (Tarmín), umidade relativa do ar (UR) e déficit de pressão de vapor (DPV) para a região Centro-Oeste do Brasil, em diferentes escalas temporais e biomas. As estimativas geralmente subestimam a Tarmáx, com exceção do produto CPC em algumas regiões, enquanto a Tarméd tende a ser superestimada, com destaque para o CPC apresentando a maior superestimação. Por outro lado, as estimativas da Tarmín geralmente superestimam essa variável, variando entre os produtos e biomas. Os resultados mostram que o produto NCEP/DOE geralmente apresenta a maior subestimação da Tarmáx, enquanto o CPC tem a maior superestimação da Tarméd. O MERRA2, por sua vez, obtém o melhor desempenho na maioria das escalas temporais e biomas para as estimativas de Tarmín. No que diz respeito à UR e ao DPV, o ERA5-Land se destaca como o produto com melhor desempenho, enquanto o GLDAS e o NCEP/DOE têm os piores resultados. Essas disparidades podem ser atribuídas às diferentes parametrizações dos processos físicos nos modelos meteorológicos utilizados por esses produtos. Além disso, a presença de rios, lagos e áreas úmidas na Amazônia pode influenciar as temperaturas máximas devido à evaporação da água e à umidade do solo. O desempenho dos produtos varia de acordo com a escala temporal, com o Ensemble e o ERA5-LAND se destacando nas estimativas diárias, enquanto o CPC é mais preciso em escalas mensais e anuais. O texto também aborda a umidade relativa do ar e o déficit de pressão de vapor, observando discrepâncias entre os produtos de reanálise devido a diferentes métodos de assimilação de dados e parametrizações. O ERA5-LAND é reconhecido como o produto mais preciso, devido à sua alta resolução espacial e incorporação de diversas fontes de dados. Em contraste, o NCEP/DOE e o JRA55 mostraram desempenho inferior em algumas variáveis e escalas temporais, destacando a importância da seleção cuidadosa dos parâmetros nos modelos de reanálise. A conclusão enfatiza a necessidade de considerar múltiplos conjuntos de dados e variáveis climatológicas para uma compreensão abrangente do clima regional.

1. INTRODUÇÃO

A região Centro-Oeste do Brasil destaca-se por sua importância na economia nacional, especialmente devido à sua expressiva produção agropecuária e à diversidade de seus biomas e paisagens (MELLO et al., 2020). Contudo, a escassez de estações meteorológicas na região representa um desafio para a obtenção de dados precisos das variáveis climáticas fundamentais, como temperatura do ar, umidade relativa do ar e déficit de pressão de vapor. Essa lacuna de informações pode impactar adversamente a produtividade e a economia local. Diante desse cenário, torna-se imperativo recorrer a produtos confiáveis para estimar essas variáveis climáticas, visando assegurar a sustentabilidade e o desenvolvimento regional. Investir em tecnologias e estratégias para o monitoramento e previsão do clima na região é crucial para um planejamento eficiente e uma gestão adequada das atividades agropecuárias, promovendo, assim, o progresso social e econômico na região (de MORAES & GONÇALVES, 2023).

Embora as estações de superfície sejam amplamente utilizadas para medições *in loco*, apresentam limitações geográficas, metodológicas e técnicas que comprometem a qualidade dos dados obtidos (ABDELMONEIM et al., 2022). A heterogeneidade na distribuição da rede de estações na região Centro-Oeste, com grandes áreas desprovidas de cobertura e alto número de falhas de medição, exige a implementação de métodos alternativos para obter dados confiáveis com resolução espacial e temporal elevadas, como é o caso das reanálises (JUNIOR et al., 2021). Produtos de reanálise proporcionam dados em grade com diversas escalas espaciais e temporais, permitindo a representação do estado atmosférico por meio de modelos atmosféricos numéricos, assimilação de dados e múltiplos conjuntos de observações para diversas variáveis (TAREK et al., 2020). São desenvolvidos a partir da combinação de modelos climáticos com dados observacionais, incluindo dados de satélite, fornecendo informações históricas de alta resolução sobre diversos parâmetros do clima. Esses dados são cruciais para análises climáticas de longo prazo, estudos de tendências climáticas e compreensão das mudanças climáticas globais (AGUTU et al., 2017). Sendo métodos essenciais para a compreensão do clima da Terra e apresentando diversas aplicações práticas em diferentes campos.

A utilização de produtos de reanálise para estimativas de variáveis climáticas oferece diversas vantagens em comparação com a coleta de dados em estações de superfície (SUN et al., 2018). A coleta sistemática e repetitiva desses dados permite obter informações consistentes ao longo do tempo, com frequência de amostragem geralmente maior, proporcionando uma

visão mais detalhada das variações climáticas. Ademais, possibilitam a obtenção de informações sobre a distribuição espacial das variáveis climáticas, aspecto essencial para compreender os padrões climáticos em larga escala (ALMAZROUI et al., 2021). Desta maneira, o uso de produtos derivados de reanálises é essencial para estudos climáticos e para o desenvolvimento econômico e social em regiões com baixa densidade de estações meteorológicas, como é o caso do Centro-Oeste brasileiro.

Neste cenário, com a variedade de produtos de reanálises disponíveis, cada um com características específicas de medição e processamento, é crucial determinar qual produto pode fornecer as melhores estimativas das variáveis climáticas em relação aos dados de superfície para essa região. Assim, o objetivo deste estudo é avaliar e validar as estimativas de temperatura do ar, umidade relativa do ar e déficit de pressão de vapor fornecidas por produtos de reanálises, na região Centro-Oeste do Brasil.

2. MATERIAL E MÉTODOS

2.1 Área de Estudo

A extensa região Centro-Oeste do Brasil, abarcando uma área de 1.612.000 km², conforme dados do IBGE em 2019 (Figura 7), encontra-se estrategicamente localizada no coração da América do Sul e engloba os estados de Mato Grosso (MT), Mato Grosso do Sul (MS), Goiás (GO) e o Distrito Federal (DF). Essa vasta porção territorial caracteriza-se pela presença predominante de quatro biomas distintos: Cerrado (Savana brasileira) com 56,8%, Amazônia com 30,0%, Pantanal com 9,4%, e Mata Atlântica com 3,8%, de acordo com os dados do IBGE em 2019. O clima na região apresenta notáveis gradientes de temperatura e precipitação, dando origem a diversas zonas climáticas conforme a classificação de Köppen-Geiger, conforme delineado por Alvares et al. (2013). Estas zonas incluem o clima Aw (tropical com inverno seco), o clima Am (tropical úmido), o clima Cwa (subtropical com inverno seco e

verão quente) e o clima Cfa (subtropical com verões quentes), contribuindo para a diversidade climática que define a região Centro-Oeste do Brasil.

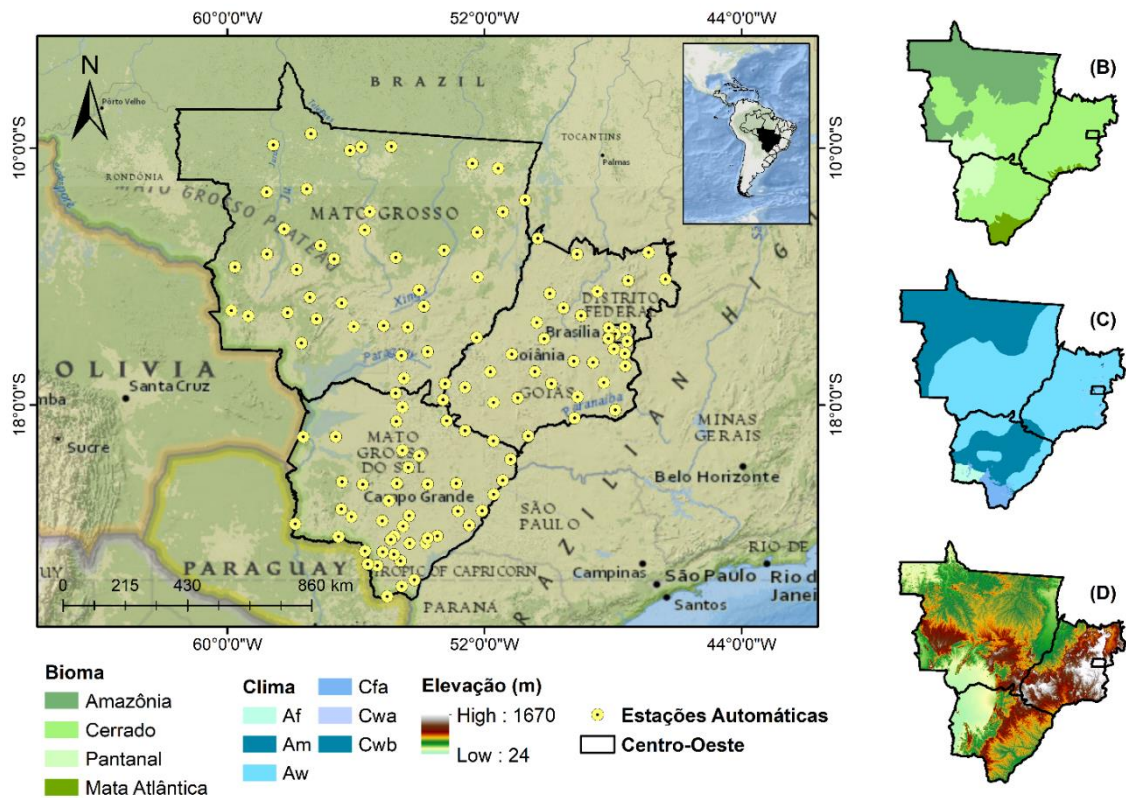


FIGURA 7 Distribuição espacial das estações meteorológicas automáticas de superfície (A), biomas (B), classificação climática (C) e altitude (D) do Centro-Oeste do Brasil.

2.2 Observações de temperatura do ar mínima, média e máxima, umidade relativa do ar e deficit de pressão de vapor

As medições de temperatura do ar (T_{ar}) mínima, média, máxima, umidade relativa do ar e déficit de pressão de vapor foram obtidas entre 2000 e 2020 em 120 estações meteorológicas automáticas de superfície pertencentes ao Instituto Nacional de Meteorologia (INMET) por meio do Banco de Dados Meteorológico para Ensino e Pesquisa (BDMEP) (Tabela 1; Anexos) (INMET, 2023). A seleção destas 120 estações foi baseada na consistência e qualidade das séries temporais a longo prazo, com um número mínimo de observações ausentes (menos de 5 a 10%). A presença de muitos dados ausentes prejudica a comparação na escala de tempo mensal e anual, o que pode comprometer a análise e interpretação dos resultados (JUNIOR et al., 2021). Ressalta-se, que as medições disponíveis apresentavam uma resolução temporal ainda maior (horária). No entanto, optamos por utilizar resoluções temporais menores para adequar os dados aos produtos de sensoriamento remoto e reanálise.

A distribuição das estações meteorológicas não representa de forma homogênea toda a extensão da região centro Oeste. A densidade (quantidade) da rede de estações pode ser atribuída a diferentes fatores, sendo um dos principais a dificuldade de acesso geográfico em algumas regiões. A região Centro-Oeste é caracterizada por possuir áreas remotas e de difícil acesso, como regiões de cerrado, florestas, montanhas e áreas pantanosas. Essas localidades muitas vezes são inacessíveis por meio de estradas, tornando difícil a instalação e manutenção de estações meteorológicas nessas regiões. Além disso, os padrões de localização das estações meteorológicas seguem a dinâmica de ocupação territorial na região.

2.3 Estimativas de temperatura do ar (Tar), umidade específica (q) e umidade relativa do ar (UR)

Foram utilizadas estimativas dos produtos *CPC Global Unified Temperature*, *European Centre for Medium-Range Weather Forecasts* (ECMWF's – ERA5-LAND), *Global Land Data Assimilation System* (GLDAS), *Japanese 55-year Reanalysis Project* (JRA-55), *Modern-Era Retrospective Analysis for Research and Applications* (MERRA-2), *National Centers for Environmental Prediction and the National Center for Atmospheric Research* (NCEP-DOE) *Reanalysis 2*, (Tabela 2). Neste estudo, foram utilizados vários produtos de reanálise para estimar a e temperatura do ar, umidade relativa do ar e déficit de pressão de vapor sobre região Centro-Oeste do Brasil. Para aumentar a confiabilidade e a precisão das estimativas, empregamos a técnica de média ensemble, que consiste na combinação de diferentes produtos. Essa abordagem permite reduzir a variabilidade e os erros associados a cada produto individual e aumentar a robustez das estimativas. Para realizar essa combinação, optamos por uma abordagem simples de média aritmética, na qual calculamos a média dos valores de precipitação e temperatura do ar de cada produto em cada escala temporal (diária, mensal e anual). Essa abordagem de média ensemble é amplamente utilizada em estudos hidrológicos e meteorológicos para melhorar a precisão das estimativas e reduzir a incerteza associada aos produtos individuais (BAN et al., 2021).

TABELA 8 Versão, resolução temporal e espacial dos produtos de reanálises utilizados de temperatura do ar (Tar), umidade específica (q) e umidade relativa do ar (UR) para a região Centro-Oeste do Brasil.

Produtos	Versão	Resolução Temporal	Variáveis	Resolução Espacial	Referência
----------	--------	--------------------	-----------	--------------------	------------

Reanálises	ERA5-Land	ERA5-Land hourly data on pressure levels	horária	UR	0.25° x 0.25°	cds.climate.coperni cus.eu
	ERA5-Land	t2m	horária	Tar	0.1° x 0.1°	cds.climate.coperni cus.eu
	GLDAS	GLDAS_NOAH 025_3H v2.1	3 horas	Tar/ <i>q</i>	0.25° x 0.25°	disc.gsfc.nasa.gov
	JRA-55	Parameters of isobaric analysis fields (anl_p125)	6 horas	Tar/UR	0.5° x 0.625°	jra.kishou.go.jp
	NCEP/DOE	NCEP-DOE Reanalysis 2: Pressure Level	Diária	UR	2.5° x 2.5°	psl.noaa.gov
	NCEP-DOE	Reanalysis 2: Gaussian Grid	diária	Tar	(192x94)	psl.noaa.gov
	MERRA-2	M2SDNXSLV v5.12.4	Diária	<i>Tar</i>	0.5° x 0.625°	disc.gsfc.nasa.gov
	CPC Precipitation /Temperature	-	Diária	<i>Tar</i>	0.5° x 0.5°	psl.noaa.gov

2.4 Cálculo para converter umidade específica (*q*) em umidade relativa (UR)

Os dados do GLDAS de umidade específica (*q*) foram convertidos em umidade relativa (UR). Calculou-se a pressão de vapor (*e*) e a saturação de pressão de vapor (*es*), Equações 1 e 2.

$$e = q \frac{p}{0.622 + 0.378q} \quad (1)$$

Sendo que *e* é pressão de vapor, *q* a umidade específica (kg/kg) e *p* a pressão atmosférica em Pascal (Pa) = 101325.

Para o cálculo da pressão de vapor do produto GLDAS foi utilizada a equação de Clausius-Clapeyron (CLAPEYRON, 1834), Equação 2:

$$es = 6.11 \exp \left[\left(\frac{L}{R_w} \right) \left(\frac{1}{t_0} - \frac{1}{t} \right) \right] \quad (2)$$

Onde 6.11hPa é a pressão de saturação de vapor no zero absoluto $t_0 = 273.15\text{K}$, Calor latente do vapor de água $L = 2.5 \times 10^6\text{J/kg}$, Constante de gás específica do vapor de água $R_w =$

$\frac{1000R}{M_w} = 461.52 \text{ J/kgK}$, onde $R = 8,3144621 \text{ J/(molK)}$ é a constante molar do gás e $M_w = 18,01528 \text{ g/mol}$ é o peso molecular do vapor de água e t é a temperatura em Kelvin (K).

Após os cálculos de pressão de vapor (e) e saturação de pressão de vapor (e_s), a umidade relativa do ar (UR) do GLDAS foi estimada, segundo a Equação 3.

$$UR = \frac{e}{e_s} \quad (3)$$

2.5 Cálculo do déficit de pressão de vapor (DPV)

Para o cálculo do déficit de pressão de vapor (DPV) utilizou-se os dados de temperatura do ar (Tar) e de umidade relativa das estações automáticas. O Déficit de Pressão de Vapor (DPV ; kPa) foi calculado a partir da Equação (4).

$$DPV = e_s - e_a \quad (4)$$

$$e_s = 0.611 \left[\exp \left(17.27 \times \frac{Tar}{Tar + 237.3} \right) \right] \quad (5)$$

$$e_a = \frac{(UR \times e_s)}{100} \quad (6)$$

Onde, DPV é o Déficit de Pressão de Vapor (kPa), e_s é a saturação de pressão de vapor, e_a é a pressão atual de vapor (kPa), Tar é a temperatura do ar medida ou estimada ($^{\circ}\text{C}$) e UR é a umidade relativa medida ou estimada (%).

2.6 Indicadores de Performance

As estimativas diárias, mensais e anuais de precipitação dos diferentes produtos foram avaliadas somente em casos em que não havia lacunas de dados nas observações correspondentes das estações meteorológicas automáticas. Foi combinada a localização geográfica de cada estação meteorológica com o pixel correspondente (mais próximo do centro de um pixel) dos produtos da grade, ou seja, de sensoriamento remoto e reanálise (Figura 9). A comparação direta dos valores ponto a pixel foi realizada para manter a integridade das

estimativas de precipitação em grade, sem alterar seus valores. Portanto, não foi realizada nenhuma reamostragem ou agregação dos dados da grade em termos de resolução espacial, pois isso exigiria a execução de todos os algoritmos de precipitação utilizados para desenvolver esses produtos - o que está fora do escopo desta análise. Assim, a comparação dos dados em grade com os dados da estação foi realizada utilizando sua resolução espacial nativa.

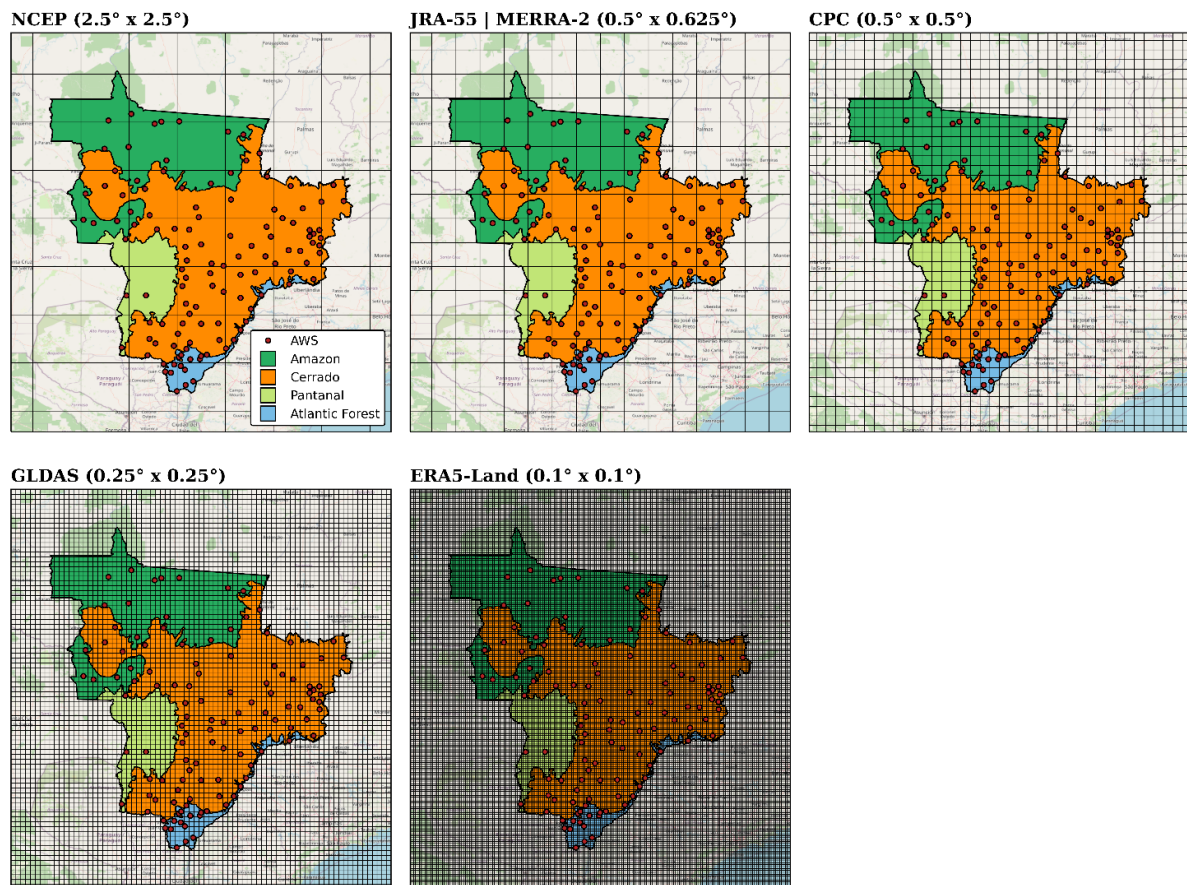


FIGURA 8 Representação espacial das localizações das estações meteorológicas e a resolução da grade (como mostrado na Tabela 8) dos produtos de temperatura do ar, umidade relativa do ar e deficit de pressão de vapor.

As médias diárias, mensais e anuais de temperatura do ar (média, máxima e mínima), umidade relativa do ar e déficit de pressão de vapor, tanto estimadas quanto medidas, foram calculadas. Para isso, empregamos a técnica de reamostragem bootstrap com 1000 interações, que nos permitiu estimar amostras aleatórias repetidas para um conjunto de dados do mesmo tamanho da amostra original. Além disso, calculamos os respectivos intervalos de confiança ($\pm 95\%$) para essas médias, que indicam a confiabilidade de nossas estimativas. A partir dessa abordagem, observamos que as médias obtidas em estações próximas apresentam diferenças significativas.

Foi feita a relação entre as medidas e estimativas de temperatura média, máxima e mínima do ar, umidade relativa do ar e déficit de pressão de vapor. Para isso, utilizou-se o índice de correlação de Spearman r . Este índice indica a relação entre dois conjuntos de dados, variando de -1 a 1. Quando o índice se aproxima de -1, temos uma forte correlação negativa. Por outro lado, quando se aproxima de 1, indica uma forte correlação positiva. Já valores próximos a zero sugerem que não há correlação entre os conjuntos de dados (conforme a Equação 7).

$$r = 1 - \frac{6 \sum d_i^2}{n^3 - n} \quad (7)$$

Onde, d_i é a diferença entre os postos de cada par de observações e n o tamanho da amostra.

A congruência entre as observações empíricas e as estimativas foi meticulosamente examinada por meio do emprego do índice "d," conforme sugerido por Willmott et al. (1985) (Equação 8). Este referido índice demonstra uma escala quantitativa que oscila entre 0 e 1, denotando, respectivamente, discordância absoluta e concordância perfeita (MACHADO et al., 2015).

$$d = 1 - \left[\frac{\sum (P_i - O_i)^2}{\sum (|P_i - O| + |O_i - O|)^2} \right] \quad (8)$$

Onde, P_i é o valor estimado da variável (na escala de tempo diária, mensal ou anual), i representa um numerador para o número de observações de 1 a n (dias, meses ou anos). O_i é o valor da variável medida, e O é a média da variável medida.

A avaliação da magnitude das discrepâncias nas estimativas fornecidas pelos produtos de sensoriamento remoto e reanálise fundamentou-se no cálculo do Erro Quadrático Médio (RMSE), cuja idealização implica valores aproximados a zero (JUNIOR et al., 2021; MACHADO et al., 2015) (Equação 9).

$$RMSE = \sqrt{\frac{\sum (P_i - O_i)^2}{n}} \quad (9)$$

A quantificação da discrepância entre os valores observados e estimados foi conduzida mediante a aplicação do Mean Absolute Error (MAE), no qual todas as disparidades individuais são ponderadas de forma equitativa, sendo desejável a obtenção de valores aproximados a zero (Equação 10).

$$MAE = \frac{\sum |P_i - O_i|}{n} \quad (10)$$

Com o intuito de avaliar a conformidade das estimativas em relação aos dados medidos, considerados como padrão ouro, empregou-se a métrica de concordância de Lin (ρ_c) (Equação 11). Este índice, situado em uma escala de -1 a 1, reflete alta concordância positiva quando atinge o valor de 1 (FANTIN et al., 2018).

$$\rho_c = \frac{2\rho\sigma_x\sigma_y}{2\sigma_x\sigma_y + (\sigma_x - \sigma_y)^2 + (\mu_x - \mu_y)^2} \quad (11)$$

Onde, ρ é o coeficiente de correlação de Pearson, σ_x e σ_y correspondem às variâncias da primeira e segunda séries de medidas e μ_x e μ_y são as médias para as duas séries.

O Percentual de Viés (PBIAS), conforme proposto por Gupta et al. (1999), representa uma métrica estatística empregada para a avaliação da disparidade entre os valores simulados por um modelo e os valores observados em uma série de dados específica. Essa medida se revela pertinente para a análise da propensão de um modelo em subestimar ou superestimar os valores observados ao longo do tempo. A condição de equilíbrio, onde a relação entre os valores simulados e observados é de 1 para 1, é expressa por um PBIAS de 0,0%. Um valor positivo de PBIAS denota uma superestimação pelo modelo, enquanto um valor negativo indica uma subestimação.

$$PBIAS = \frac{\sum (P_i - O_i)^2}{\sum O_i} \times 100 \quad (12)$$

Com base nas avaliações individuais de cada produto (sensoriamento remoto, reanálise e modelo combinado), é viável conduzir a classificação dos modelos por meio de diversas

métricas de desempenho, como r , d , RMSE, MAE, PBIAS e LIN. Adicionalmente, a classificação do modelo abrangente (MR) foi calculada para consolidar todas as alternativas de classificação, conforme proposto por Avila-Diaz et al. (2020). Essa medida reveste-se de significância, uma vez que possibilita a avaliação da coerência de cada modelo diante das variadas perspectivas de classificação (índices e métricas) (Equação 13).

$$M_R = 1 - \frac{1}{n \times m} \sum_{i=1}^n (Rank_{i_r} + Rank_{i_d} + Rank_{i_{RMSE}} + Rank_{i_{MAE}} + Rank_{i_{PBIAS}} + Rank_{i_{Lin}}) \quad (13)$$

onde n é o número total de índices, m é o número de modelos e o $Rank_i$ 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).

3.RESULTADOS

3.1 Temperatura do ar máxima (Tar_{max})

As estimativas de temperatura máxima do ar (Tar_{max}) revelaram uma tendência de subestimação em relação às medições realizadas na maioria dos casos, abrangendo diversas escalas temporais, a saber: diária, mensal e anual (Figura 9). Na escala diária, as estimativas de Tar_{max} manifestaram uma subestimação média de 6,1%, destacando-se o produto NCEP/DOE como aquele que apresentou a maior subestimação, atingindo 6,1%, enquanto o CPC evidenciou uma discreta superestimação de 2% (Figura 9). Ao considerar a escala mensal, observou-se uma consistente subestimação nas estimativas de Tar_{max} , com exceção dos produtos CPC e MERRA2. A subestimação média foi de -5,9%, sendo o NCEP/DOE o produto com a máxima subestimação (5,9%), e o CPC com uma leve superestimação de 2% (Figura 9). Nas estimativas anuais, todos os produtos demonstraram uma propensão à subestimação da Tar_{max} . O NCEP/DOE registrou a maior subestimação anual da Tar_{max} , atingindo 5,9%, enquanto o CPC e MERRA2 apresentaram uma superestimação de 2% e 0,9%, respectivamente (Figura 9).

Ao analisar os diferentes biomas, observa-se uma tendência geral de subestimação da Tar_{max} , com a exceção do CPC, que apresentou uma discreta superestimação na Amazônia

(1,2%) e no Cerrado (2%) (Figura 9). O produto NCEP/DOE revelou-se como aquele com a maior subestimação da $T_{ar_{max}}$ nessas regiões, com valores de 10,6% e 7,1%, respectivamente. Na Mata Atlântica, todos os produtos exibiram uma subestimação da $T_{ar_{max}}$, sendo o NCEP/DOE o mais proeminente com uma subestimação de 9,6%, enquanto o MERRA2 apresentou a menor subestimação, registrando apenas 0,3% (Figura 9). No Pantanal, os produtos MERRA2 e CPC superestimaram a $T_{ar_{max}}$, ao passo que os demais produtos subestimaram. O NCEP/DOE destacou-se pela máxima subestimação da $T_{ar_{max}}$ no Pantanal, com valores de 10,8% na escala diária e 10,4% nas escalas mensal e anual.

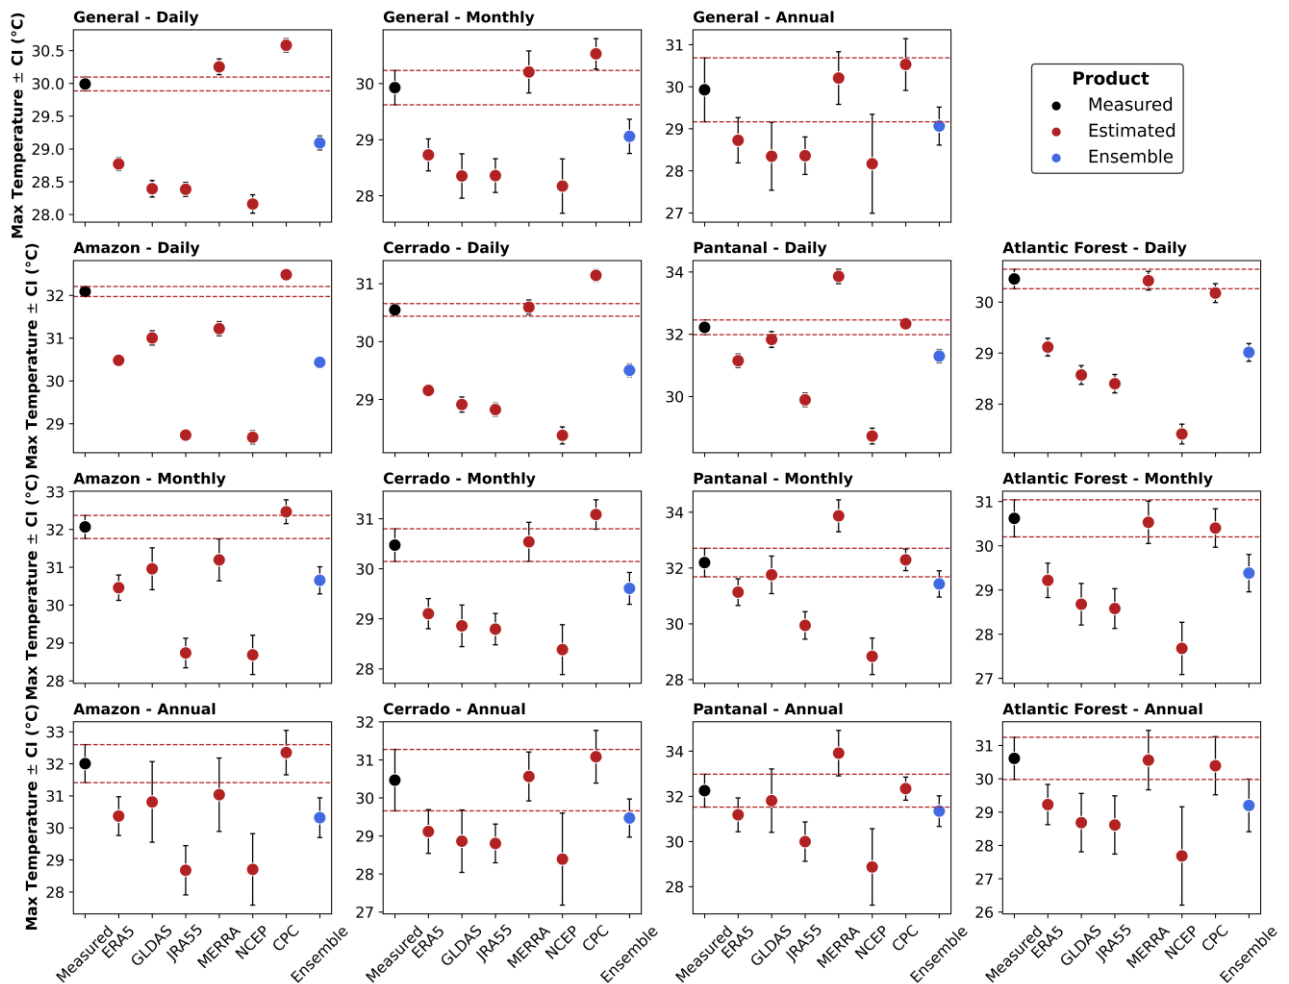


FIGURA 9 Valores médios de temperatura do ar máxima \pm intervalo de confiança (IC) diário (A), mensal(B) e anual(C) medido por estações meteorológicas automáticas do INMET e estimado por produtos ERA5-LAND, GLDAS, JRA55, MERRA2, NCEP/DOE, CPC e a média multi-modelo Ensemble na região Centro Oeste, Brasil. Para (A), foi calculada a média dos valores diários para todo o período de estudo, enquanto para (B), foi calculada a média dos valores mensais para todos os meses durante o período de estudo, e os valores anuais em (C) foram os valores anuais calculados para todos anos durante o período de estudo.

Ao analisar as estimativas diárias de temperatura máxima do ar ($T_{ar_{max}}$) para a região do Centro-Oeste, os modelos Ensemble e ERA5-LAND destacaram-se ao obterem os mais

elevados índices de classificação, com valores de MR de 0,83 e 0,78, respectivamente (Figura 10). Em contraste, o desempenho do modelo NCEP/DOE foi considerado o menos eficaz, registrando um MR de 0,33, indicando estimativas menos precisas (Figura 10). Nas escalas mensal e anual, o modelo CPC demonstrou a melhor performance na estimativa de Tar_{max} , com um MR de 0,76. Por outro lado, o modelo NCEP/DOE evidenciou o pior desempenho nessas escalas temporais, com um MR de 0, indicando que suas estimativas não são confiáveis (Figura 10).

Para o bioma Amazônia, o modelo CPC destacou-se como o mais eficaz nas estimativas diárias, mensais e anuais de Tar_{max} , obtendo um MR de 0,85 (Figura 10). Em contrapartida, o modelo NCEP/DOE apresentou o pior desempenho na escala diária, registrando um MR de 0,30. No bioma Cerrado, os modelos Ensemble e ERA5-LAND alcançaram os melhores rankings nas estimativas diárias de Tar_{max} , com MR de 0,82 e 0,75, respectivamente (Figura 10). Nas escalas mensal e anual, os modelos CPC e MERRA2 alcançaram os melhores índices em relação aos demais produtos. Por outro lado, o modelo NCEP/DOE revelou-se com o pior desempenho em todas as escalas temporais, com um MR de 0,25 (Figura 10). Na Mata Atlântica, o modelo CPC exibiu a melhor performance nas estimativas diárias de Tar_{max} , com um MR de 0,83, enquanto o modelo NCEP/DOE apresentou o pior desempenho, com um MR de 0,25 (Figura 10). No Pantanal, o modelo ERA5-LAND demonstrou a melhor performance nas estimativas diárias, mensais e anuais de Tar_{max} , com MR de 0,83, 0,82 e 0,80, respectivamente. O modelo NCEP/DOE, por outro lado, apresentou o pior desempenho em todas as escalas temporais, registrando um MR de 0,26.

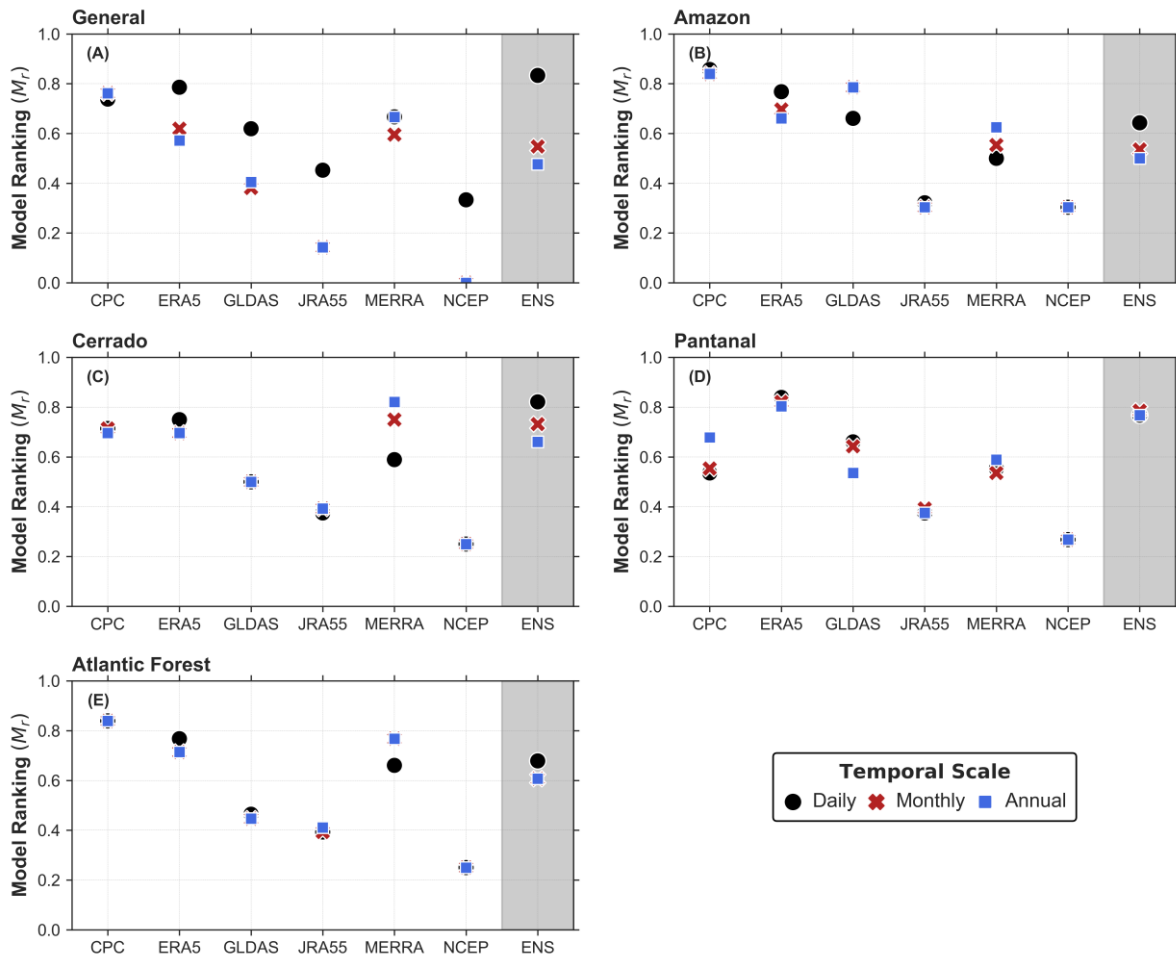


FIGURA 10 Classificação das estimativas de temperatura do ar máxima ($T_{ar_{max}}$) pelos produtos CHIRPS, CPC, GLDAS, GPCP, GPM, MERRA, TRMM, ENS e a média multi-modelo Ensemble utilizando métricas de desempenho (r , d , RMSE, MAE, PBIAS e LIN) correspondente a dados diário, mensal e anual (A) e aos biomas Amazônia (B), Cerrado (C), Mata Atlântica (D) e Pantanal (E), região Centro Oeste, Brasil.

3.2 Temperatura do ar média ($T_{ar_{méd}}$)

Na região do Centro-Oeste, as estimativas da temperatura média do ar ($T_{ar_{méd}}$) exibiram, em sua maioria, uma tendência à superestimação (Figura 11). Notavelmente, o CPC apresentou a máxima superestimação em todas as escalas temporais, registrando valores de 6,9% nas escalas diária, mensal e anual. No bioma Amazônia, o CPC também se destacou pela máxima superestimação das estimativas de $T_{ar_{méd}}$, atingindo 6,6% nas escalas diária, mensal e anual (Figura 11). Em contrapartida, o NCEP/DOE revelou a mais expressiva subestimação na escala diária (1,9%), mensal (1,9%) e anual (2%). No bioma do Cerrado, as estimativas de $T_{ar_{méd}}$ seguiram um padrão semelhante, com o CPC apresentando a máxima superestimação de 6,9%,

enquanto o GLDAS revelou a mais significativa subestimação, atingindo -2,2% (Figura 11). Na Mata Atlântica, as estimativas de $T_{ar\text{méd}}$ foram subestimadas pelos produtos GLDAS e NCEP/DOE, ao passo que os demais produtos demonstraram superestimação. O CPC e o JRA55 se destacaram com a máxima superestimação, enquanto o NCEP/DOE evidenciou a máxima subestimação (Figura 11). No Pantanal, o MERRA2 apresentou a mais expressiva superestimação nas estimativas diárias (5,8%), mensais e anuais (6%). Por outro lado, o NCEP/DOE revelou a máxima subestimação em todas as escalas temporais, registrando valores de 4,5%, 4,2% e 4,3%, respectivamente (Figura 11).

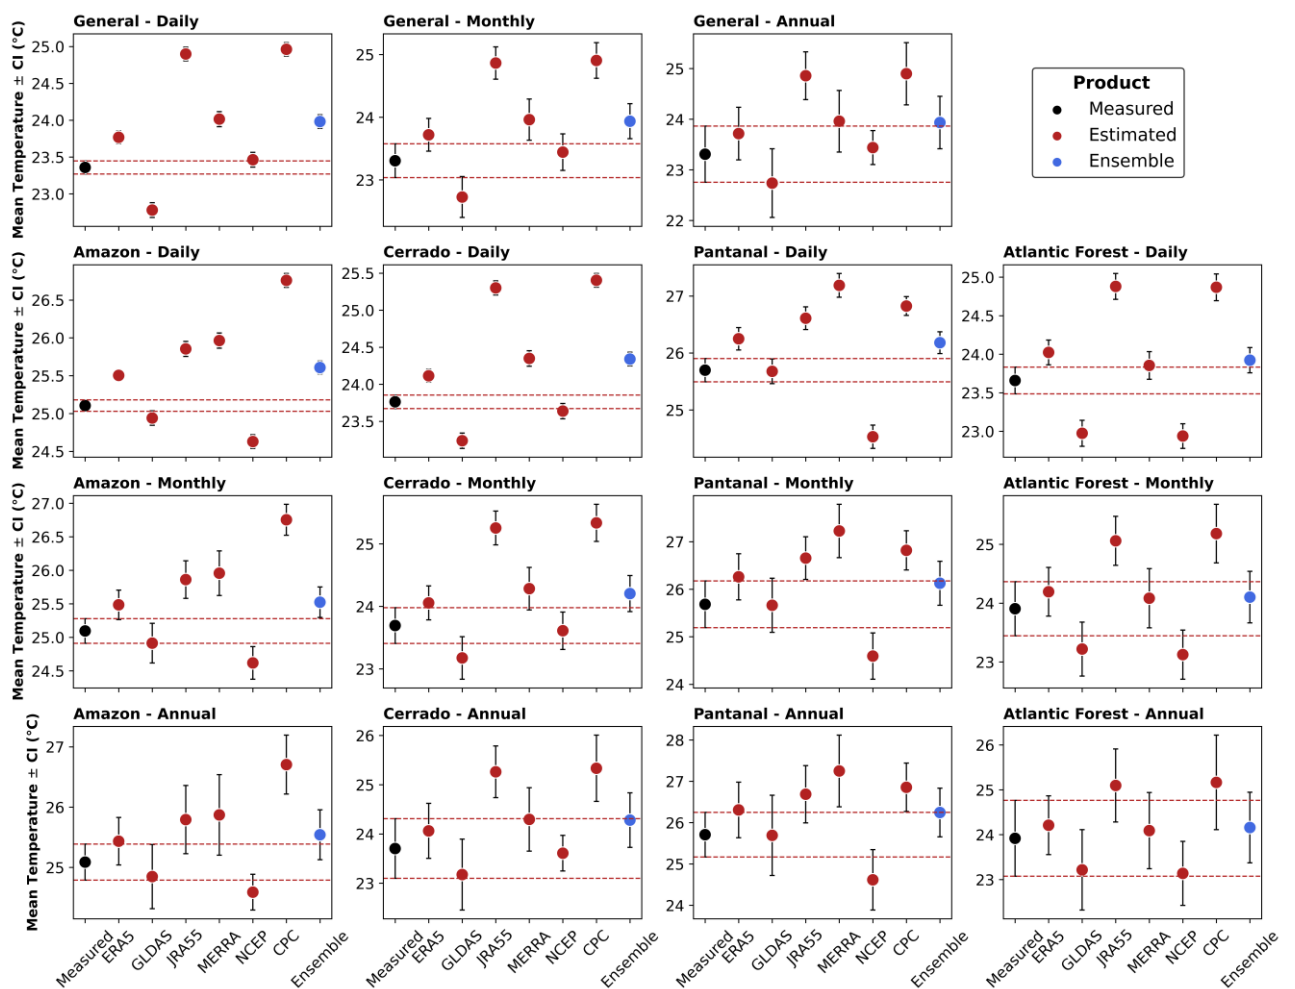


FIGURA 11 Valores médios de temperatura do ar média \pm intervalo de confiança (IC) diário (A), mensal(B) e anual(C) medido por estações meteorológicas automáticas do INMET e estimado por produtos ERA5-LAND, GLDAS, JRA55, MERRA2, NCEP/DOE, CPC e a média multi-modelo Ensemble na região Centro Oeste, Brasil. Para (A), foi calculada a média dos valores diários para todo o período de estudo, enquanto para (B), foi calculada a média dos

valores mensais para todos os meses durante o período de estudo, e os valores anuais em (C) foram os valores anuais calculados para todos os anos durante o período de estudo.

O produto ERA5-LAND demonstrou uma destacada performance nas estimativas da temperatura do ar média ($T_{ar_{méd}}$) para todas as regiões e escalas temporais consideradas (FIGURA 12). Na região do Centro-Oeste, o ERA5-LAND alcançou um índice de classificação (MR) de 0,88 na escala diária, 0,83 na escala mensal e 0,83 na escala anual, refletindo uma alta precisão em suas estimativas. Em contraste, o CPC revelou o desempenho menos eficaz, registrando MR de 0,38, 0,04 e 0,07, respectivamente. Na Amazônia, tanto o Ensemble quanto o ERA5-LAND se destacaram como os produtos mais eficientes nas estimativas diárias de $T_{ar_{méd}}$, com MR de 0,85 e 0,78, respectivamente (Figura 12). Nas escalas mensal e anual, o ERA5-LAND manteve sua superioridade, apresentando MR de 0,78 e 0,87, enquanto o CPC evidenciou o desempenho menos eficaz nessas escalas, com MR de 0,28 e 0,32 (Figura 12).

No Cerrado, o ERA5-LAND também se revelou como o melhor em todas as escalas temporais, atingindo MR de 0,87 tanto na escala diária quanto na mensal e anual (Figura 12). Por outro lado, o CPC registrou o desempenho menos eficiente em todas as escalas, com MR de 0,28 na escala diária e 0,26 na escala mensal e anual. Na Mata Atlântica, tanto o Ensemble quanto o ERA5-LAND destacaram-se como os produtos mais eficazes em todas as escalas temporais, com MR de 0,87 para o Ensemble e 0,76 para o ERA5-LAND (Figura 12). O JRA55 evidenciou o desempenho menos eficiente em todas as escalas, com MR de 0,28 na escala diária e mensal, e 0,30 na escala anual. No Pantanal, o Ensemble e o ERA5-LAND novamente mostraram-se como os produtos mais eficientes. Ambos alcançaram MR de 0,83 nas estimativas diárias de $T_{ar_{méd}}$, enquanto o Ensemble obteve MR de 0,87 nas estimativas mensais e anuais. O CPC apresentou o desempenho menos eficiente na escala diária, com MR de 0,28, enquanto o MERRA2 revelou o desempenho menos eficaz na escala anual (Figura 12).

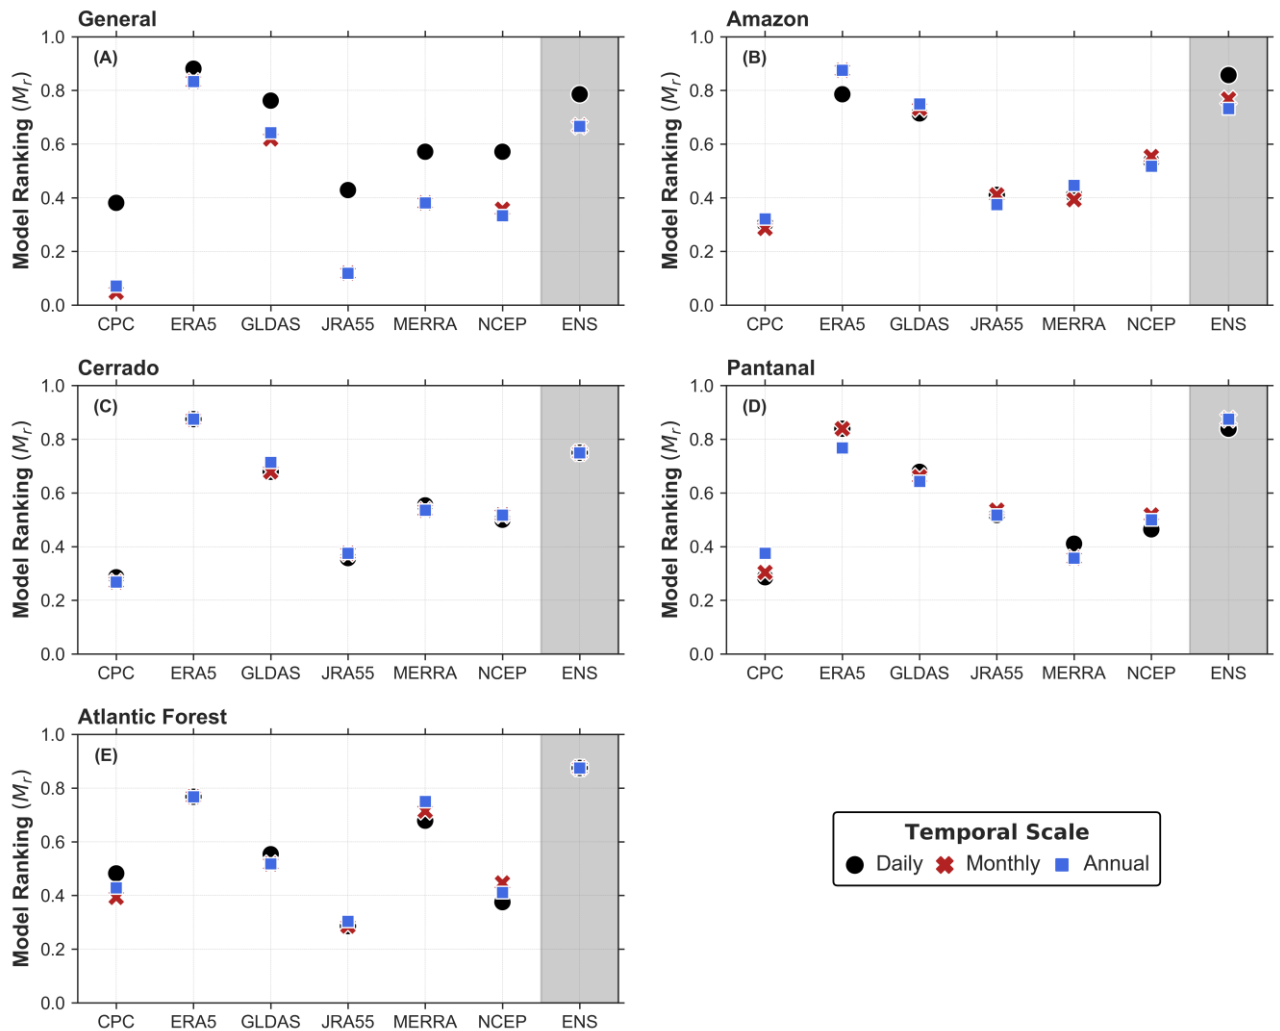


FIGURA 12 Classificação das estimativas de temperatura do ar média ($T_{ar\ media}$) pelos produtos CHIRPS, CPC, GLDAS, GPCP, GPM, MERRA, TRMM, ENS e a média multi-modelo Ensemble utilizando métricas de desempenho (r , d , RMSE, MAE, PBIAS e LIN) correspondente a dados diário, mensal e anual (A) e aos biomas Amazônia (B), Cerrado (C), Mata Atlântica (D) e Pantanal (E), região Centro Oeste, Brasil.

3.3 Temperatura do ar mínima ($T_{ar\ min}$)

As estimativas diárias, mensais e anuais de temperatura mínima do ar ($T_{ar\ min}$) para o Centro-Oeste apresentaram superestimação em relação às medições realizadas (Figura 13). O produto JRA55 teve a maior superestimação, com 13,2%, enquanto o GLDAS apresentou a menor superestimação, com 0,8%. Na Amazônia, todos os produtos superestimaram a $T_{ar\ min}$ em todas as escalas temporais. O JRA55 teve a maior superestimação, com 11,3% na escala diária e mensal, e 10,7% na escala anual. O GLDAS teve superestimação de 0,3% na escala diária e mensal, e 0,1% na escala anual (Figura 13).

No Cerrado, todos os produtos também apresentaram superestimação das estimativas de $T_{ar\ min}$ em relação às medições. O JRA55 teve a maior superestimação, com 13,1% em todas as

escalas temporais. O MERRA2 teve superestimação de 1,5% na escala diária, mensal e anual (Figura 13). Para a Mata Atlântica, a maioria dos produtos superestimou a $T_{ar\min}$, exceto o MERRA2, que apresentou subestimação. O JRA55 teve a maior superestimação, com 12,8% na escala diária, 11,6% na escala mensal e 11,8% na escala anual. Por outro lado, o MERRA2 subestimou a $T_{ar\min}$, com 1,1% na escala diária, 1,3% na escala mensal e 1,2% na escala anual (Figura 13). No Pantanal, todos os produtos analisados superestimaram a $T_{ar\min}$ em todas as escalas temporais. O JRA55 teve a maior superestimação, com 10,8% na escala diária, 10,9% na escala mensal e 11% na escala anual. O GLDAS teve a menor superestimação, com 0,4% na escala diária, 0,6% na escala mensal e 0,5% na escala anual.

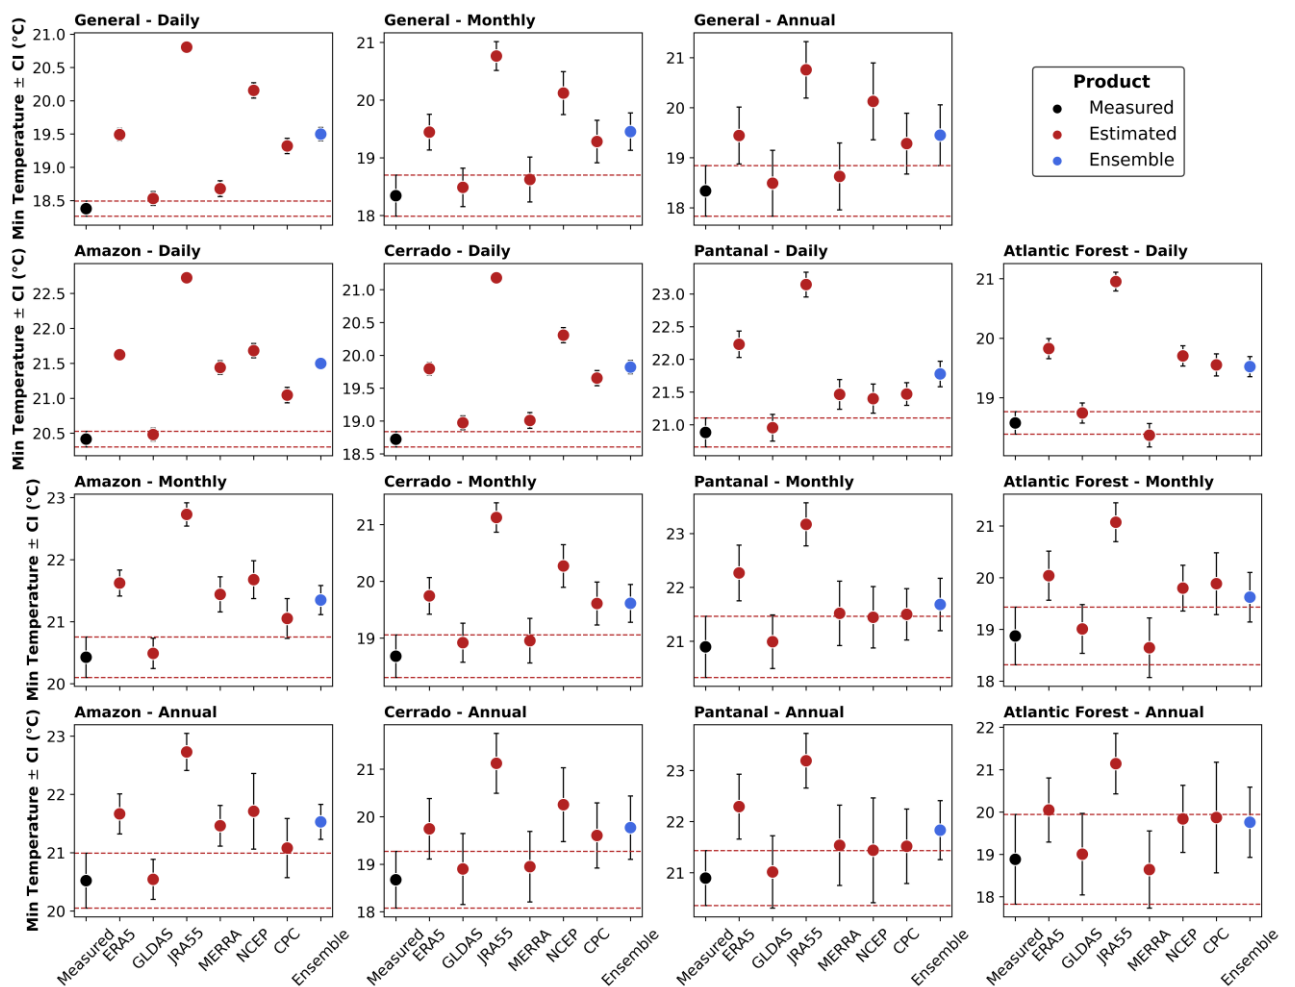


FIGURA 13 Valores médios de temperatura do ar mínima \pm intervalo de confiança (IC) diário (A), mensal(B) e anual(C) medido por estações meteorológicas automáticas do INMET e estimado por produtos ERA5-LAND, GLDAS, JRA55, MERRA2, NCEP/DOE, CPC e a média multi-modelo Ensemble na região Centro Oeste, Brasil. Para (A), foi calculada a média dos valores diários para todo o período de estudo, enquanto para (B), foi calculada a média dos

valores mensais para todos os meses durante o período de estudo, e os valores anuais em (C) foram os valores anuais calculados para todos anos durante o período de estudo.

No Centro-Oeste, o produto MERRA2 obteve o melhor desempenho na estimativa diária de temperatura mínima do ar ($T_{ar_{mín}}$), com M_R de 0,83 (FIGURA 14). O JRA55 teve o pior desempenho ($M_R= 0,33$). Nas estimativas mensais e anuais de $T_{ar_{mín}}$, o GLDAS obteve o melhor desempenho mensal ($M_R= 0,76$) e anual ($M_R= 0,80$), enquanto o JRA55 teve o menor desempenho mensal ($M_R= 0,02$) e anual ($M_R= 0,04$). Na Amazônia, o GLDAS teve o melhor desempenho em todas as escalas temporais de $T_{ar_{mín}}$ ($M_R= 0,85$ a $0,89$). Por outro lado, o JRA55 teve o pior desempenho ($M_R= 0,25$) (Figura 14).

No Cerrado e Mata Atlântica, o MERRA2 teve o melhor desempenho na estimativa de $T_{ar_{mín}}$ em todas as escalas temporais, enquanto o JRA55 apresentou o pior desempenho (Figura 14). No Cerrado, o MERRA2 obteve valores de M_R de 0,83 (diária), $M_R= 0,83$ (mensal) e $M_R= 0,80$ (anual). Por outro lado, o JRA55 obteve valores de M_R que variaram entre 0,25 e 0,32 (Figura 14). Na Mata Atlântica, o MERRA2 apresentou valores de M_R acima de 0,85. O JRA55 teve valores de M_R entre 0,25 e 0,28. No Pantanal, as estimativas diárias de $T_{ar_{mín}}$ do produto Ensemble ($M_R= 0,80$) e do MERRA2 ($M_R= 0,76$) tiveram os melhores desempenhos em relação aos outros produtos analisados (Figura 14). Nas escalas mensal e anual, o MERRA2 teve o melhor desempenho, com um M_R de 0,82 e 0,83, respectivamente. As estimativas de $T_{ar_{mín}}$ pelo JRA55 apresentaram os piores desempenhos em todas as escalas analisadas.

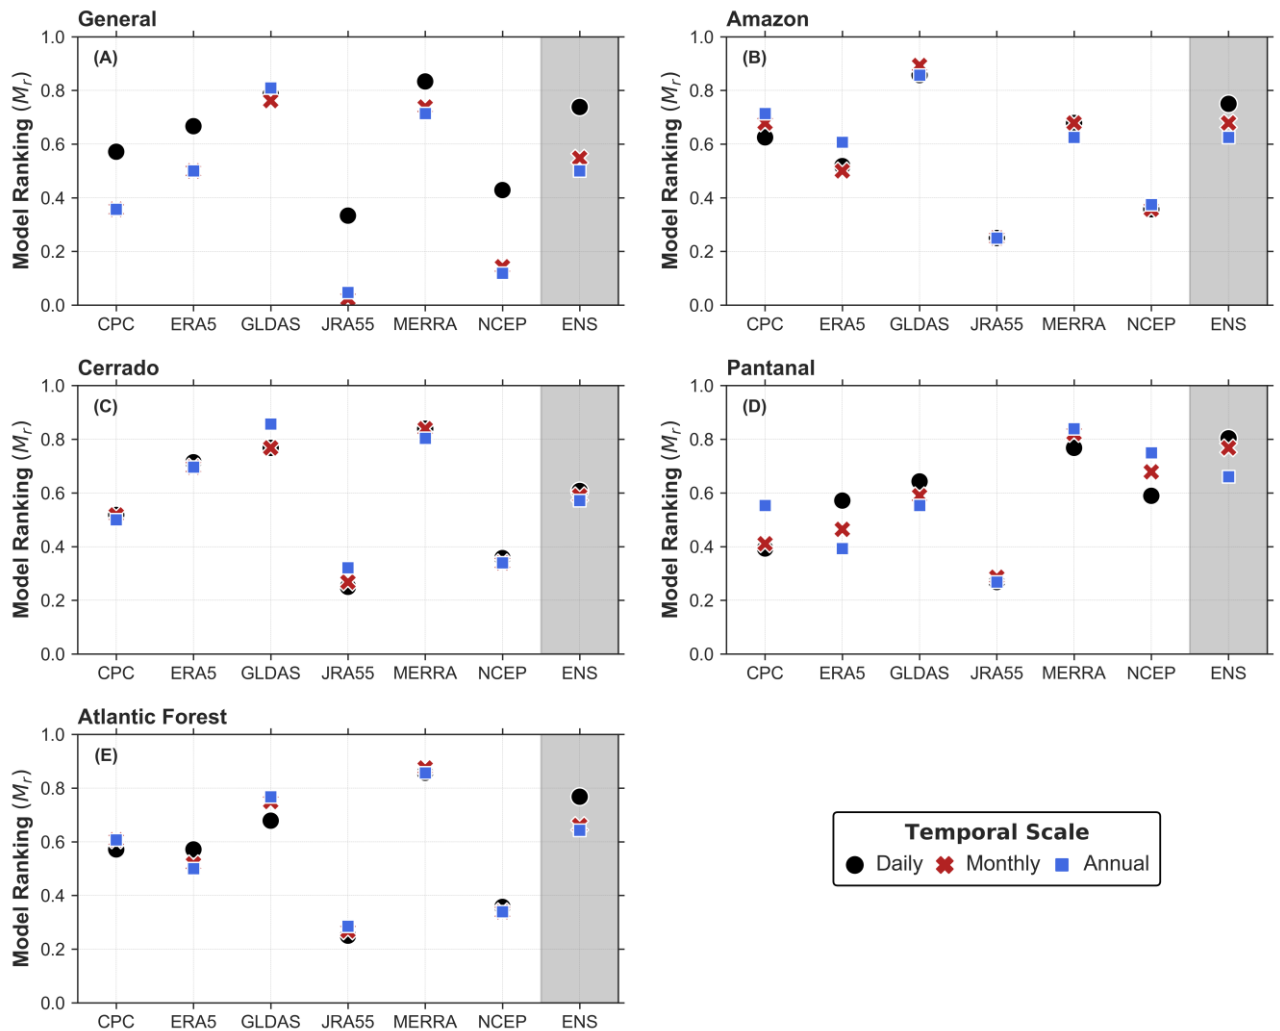


FIGURA 14 Classificação das estimativas de temperatura do ar mínima ($T_{ar_{min}}$) pelos produtos CHIRPS, CPC, GLDAS, GPCP, GPM, MERRA, TRMM, ENS e a média multi-modelo Ensemble utilizando métricas de desempenho (r , d , RMSE, MAE, PBIAS e LIN) correspondente a dados diário, mensal e anual (A) e aos biomas Amazônia (B), Cerrado (C), e Pantanal (D) e Mata Atlântica (E), região Centro Oeste, Brasil.

3.4 Umidade relativa do ar (UR)

No Centro-Oeste, o produto ERA5-Land obteve o melhor desempenho nas estimativas de umidade relativa do ar (UR) tanto nas escalas diária (M_R de 0,83), mensal e anual ($M_R = 0,75$), quanto para os biomas do Centro-Oeste do Brasil (Amazônia $M_R = 0,75$; Cerrado, Pantanal e Mata Atlântica $M_R = 0,78$). O NCEP/DOE teve o pior desempenho na escala diária ($M_R = 0,41$) e para o bioma Amazônia ($M_R = 0,21$), já o GLDAS, nas estimativas mensal, anual ($M_R = 0,16$) e para os biomas Cerrado ($M_R = 0,28$), Pantanal ($M_R = 0,21$) e Mata Atlântica ($M_R = 0,14$), Figura 15.

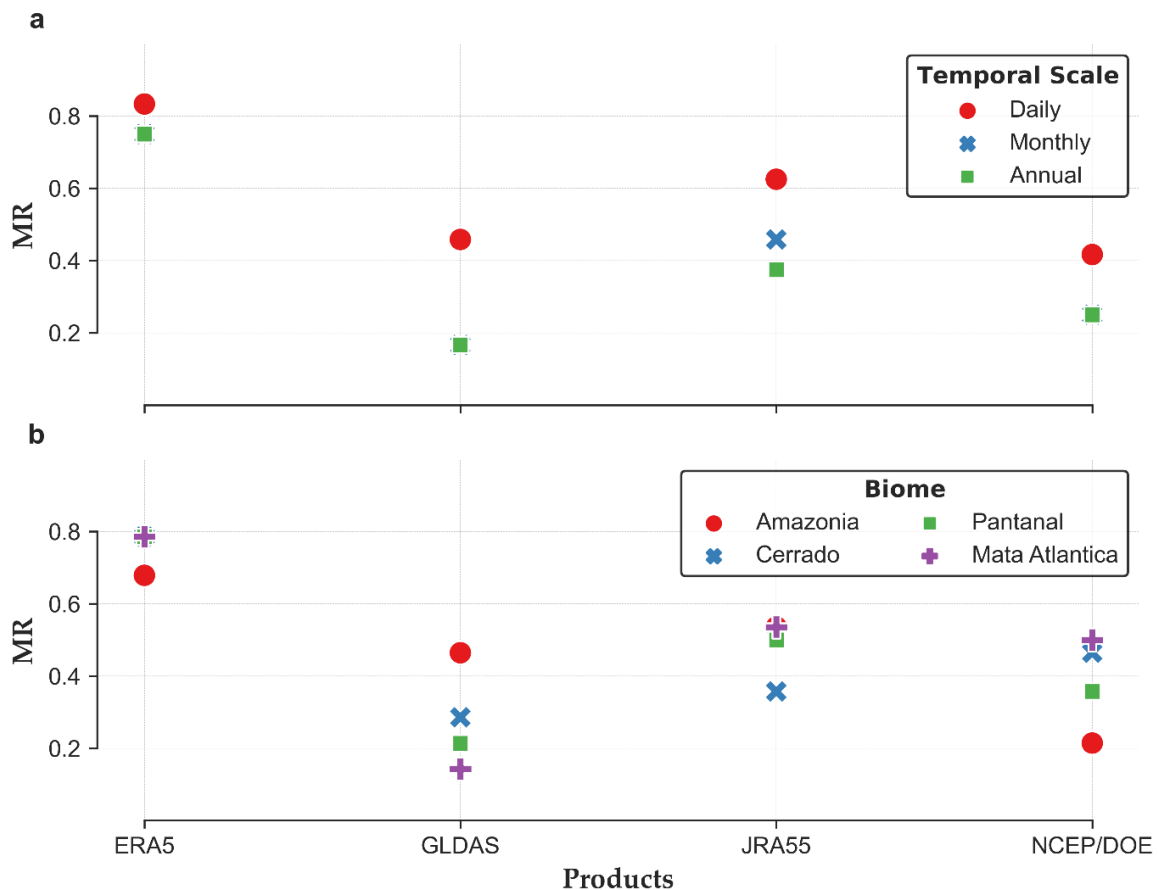


FIGURA 15 Classificação das estimativas de umidade relativa do ar (*UR*) pelos produtos ERA5-Land, GLDAS, JRA55 e NCEP/DOE utilizando métricas de desempenho (r , d , RMSE, MAE, PBIAS e LIN) correspondentes a dados diário, mensal, anual e aos biomas Amazônia, Cerrado, Pantanal e Mata Atlântica, região Centro Oeste, Brasil.

3.5 Déficit de pressão de vapor (DPV)

No Centro-Oeste, o produto ERA5-Land obteve o melhor desempenho nas estimativas de déficit de pressão de vapor (*DPV*) tanto nas escalas diária (M_R de 0,83), mensal e anual ($M_R = 0,75$) como também para os biomas do Centro-Oeste do Brasil (Amazônia $M_R = 0,71$; Cerrado, Pantanal e Mata Atlântica $M_R = 0,78$), Figura 16. O JRA55 teve o pior ranking nas estimas de DPV nas escalas diária ($M_R = 0,41$), mensal ($M_R = 0,04$) e anual ($M_R = 0,12$), assim como, para os biomas Amazônia ($M_R = 0,28$), Cerrado ($M_R = 0,21$) e Mata Atlântica ($M_R = 0,25$), já para o Pantanal, o GLDAS teve o pior desempenho ($M_R = 0,21$), Figura 16.




FIGURA 16 Classificação das estimativas de déficit de pressão de vapor (*DPV*) pelos produtos ERA5-Land, GLDAS, JRA55 e NCEP/DOE utilizando métricas de desempenho (r , d , RMSE, MAE, PBIAS e LIN) correspondentes a dados diário, mensal, annual e aos biomas Amazônia, Cerrado, Pantanal e Mata Atlântica, região Centro Oeste, Brasil.

4. DISCUSSÃO

4.1 Temperatura do ar

Houve subestimação nas estimativas de temperatura máxima provenientes do NCEP/DOE em relação aos valores medidos, enquanto o CPC apresentou superestimação na Amazônia e no Cerrado. Isso pode ter ocorrido devido aos modelos meteorológicos utilizados pelo NCEP/DOE e pelo CPC empregar diferentes parametrizações dos processos físicos que influenciam as temperaturas máximas. Essas parametrizações envolvem simplificações e aproximações das complexas interações atmosféricas, o que pode levar a diferenças nas estimativas (ARAGHI et al., 2022).

Além disso, a presença de rios, lagos e áreas úmidas na Amazônia pode influenciar as temperaturas máximas, uma vez que a evaporação da água e a umidade do solo podem afetar o balanço de energia na região (HESSLEROVÁ et al., 2019). Esses modelos com

parametrizações inadequadas desses processos podem levar a superestimativas ou subestimação das temperaturas máximas. Além disso, a umidade atmosférica pode influenciar a formação de nuvens e a ocorrência de precipitação, o que afeta as temperaturas máximas (ALESHINA et al., 2021).

O desempenho dos diferentes produtos nas estimativas de temperatura máxima variou de acordo com a escala temporal considerada. O Ensemble e o ERA5-LAND foram considerados os mais precisos nas estimativas diárias de temperatura máxima, o que sugere que esses modelos têm uma melhor capacidade de representar os eventos meteorológicos de curta duração que influenciam as temperaturas máximas (ARAÚJO et al., 2022). Por outro lado, o CPC foi identificado como o melhor em desempenho nas escalas mensal e anual, indicando que esse produto tenha uma melhor performance em capturar as variações de longo prazo nas temperaturas máximas. Isso pode ser resultado de uma melhor representação dos padrões climáticos dominantes em cada região ao longo de períodos mais longos, como os padrões sazonais e anuais (SALEHIE et al., 2022).

O CPC teve o pior desempenho nas estimativas diárias de temperatura máxima pode estar relacionada a limitações específicas desse modelo, como parametrizações físicas menos precisas ou resolução espacial e temporal inadequadas para capturar as variações diárias das temperaturas máximas. É importante ressaltar que essas limitações podem não se aplicar necessariamente às escalas mensal e anual, nas quais o CPC foi considerado o melhor em desempenho. É importante salientar que essas avaliações de desempenho são baseadas em comparações entre as estimativas dos modelos e os dados observados, e podem ser influenciadas por diversos fatores, como a qualidade dos dados observados e a representatividade das estações de medição (MORICE et al., 2021). Além disso, diferentes regiões geográficas podem apresentar desafios específicos para a modelagem das temperaturas máximas, como a presença de influências locais ou a complexidade dos sistemas atmosféricos regionais.

Para a temperatura média, o produto ERA5-LAND foi identificado com o melhor desempenho nas estimativas de temperatura média em todas as regiões e escalas temporais. O ERA5-LAND é conhecido por sua alta qualidade e precisão na representação dos processos atmosféricos. O ERA5-LAND incorpora uma ampla gama de observações meteorológicas, como dados de satélite, estações meteorológicas e sondagens atmosféricas, em um modelo de assimilação de dados sofisticado (XU et al., 2022). Isso permite que o ERA5-LAND capture com mais precisão as variações nas temperaturas máximas. A sua resolução espacial mais fina

em comparação com outros produtos, sendo capaz de capturar variações mais detalhadas e representar melhor características locais que podem influenciar as temperaturas máximas. Além disso, o ERA5-LAND fornece estimativas em intervalos de tempo mais curtos, o que possibilita uma melhor representação das variações horárias e diárias das temperaturas máximas.

Além disso, O ERA5-LAND leva em consideração informações detalhadas sobre características do solo e vegetação, como cobertura vegetal, tipo de solo e umidade do solo (MUÑOZ-SABATER et al., 2021). Esses dados são essenciais para entender como as propriedades do solo e a vegetação afetam as temperaturas máximas. Ao incorporar essas informações em seu modelo, o ERA5-LAND consegue melhorar as estimativas da temperatura máxima, especialmente em áreas com diferentes tipos de cobertura vegetal e uso do solo.

Para a temperatura mínima, as estimativas do JRA55 apresentaram uma superestimação em todas as regiões e escalas temporais analisadas. Isso pode estar relacionado aos erros nos dados de entrada utilizados no modelo. O JRA55 incorpora uma ampla gama de observações, como dados de satélite, estações meteorológicas e sondagens atmosféricas, para reanalisar as condições atmosféricas (KOBAYASHI et al., 2015). No entanto, se houver imprecisões ou lacunas nos dados de entrada, isso pode levar a estimativas incorretas da temperatura mínima.

Além disso, a configuração do modelo do JRA55 desempenha um papel importante na superestimação das temperaturas mínimas. Os parâmetros e esquemas físicos do modelo, como a parametrização da convecção atmosférica e a interação solo-atmosfera, são determinantes na simulação das temperaturas mínimas (KOBAYASHI et al., 2015). Se esses parâmetros não estiverem adequadamente ajustados para as condições específicas das regiões analisadas, é provável que ocorra uma superestimação sistemática das temperaturas mínimas.

Outro fator importante é a influência de fenômenos locais. No qual, a ocorrência de inversões térmicas, que são comuns em certas áreas e períodos do ano, pode levar a uma distribuição de temperaturas mínimas diferente do esperado (CHEN et al., 2019). Se o modelo não for capaz de capturar adequadamente esses fenômenos ou se a resolução espacial do modelo for insuficiente para representá-los, é provável que ocorra uma superestimação das temperaturas mínimas.

4.2 Umidade relativa do ar e déficit de pressão de vapor

As disparidades observadas entre as estimativas dos produtos de reanálise estão intrinsecamente relacionadas ao tipo e à quantidade de observações assimiladas em cada processo de reanálise. Adicionalmente, as variações nos modelos de parametrização física introduzem respostas distintas associadas às diferentes abordagens de reanálise (WANG & ZENG, 2012). Nessa perspectiva, pode-se considerar a superfície terrestre como um modelo de superfície da Terra (LSM), no qual cada reanálise incorpora modelos singulares em sua estrutura. Tais modelos de superfície da Terra divergem em suas formulações, abrangendo variáveis do sistema climático, como precipitação, escoamento superficial, evaporação e teor de água no solo, além de radiação e fluxos de calor sensível e latente, os quais retroalimentam o sistema de reanálise. Essa complexidade na composição dos LSMs pode contribuir para as divergências entre as estimativas resultantes (WANG & ZENG, 2012).

Os produtos de reanálise desempenham um papel crucial na compreensão das condições climáticas e são amplamente utilizados para análises climatológicas de longo prazo. No caso específico do produto ERA5-Land, desenvolvido pelo Centro Europeu de Previsões Meteorológicas de Médio Prazo (ECMWF), observa-se uma notável melhoria na estimativa da umidade relativa do ar em relação a produtos anteriores. Segundo Hersbach et al. (2020), o ERA5-Land oferece uma resolução espacial de 9 km e combina informações de múltiplas fontes, incluindo observações in situ e dados de satélites, para gerar estimativas coerentes e confiáveis de variáveis meteorológicas, incluindo a umidade relativa. Essas melhorias são cruciais para o entendimento das interações atmosféricas e hidrológicas em diferentes escalas, e têm aplicações significativas em estudos climáticos e em áreas como a agricultura e a gestão de recursos hídricos.

O ERA-5 se destaca como o melhor produto entre os produtos examinados neste estudo, em virtude de sua habilidade em disponibilizar informações mais minuciosas, atribuível à sua resolução espacial mais precisa, destaca-se por sua ampla validação e reconhecida habilidade em reproduzir com precisão elementos climáticos em diversas escalas temporais (LIU et al., 2021; XU et al., 2022). Esta eficácia é evidenciada pelo excelente desempenho nas estimativas de umidade relativa do ar e déficit de pressão de vapor, abrangendo escalas diárias, mensais e anuais, além de contemplar os diferentes biomas na região do Centro-Oeste do Brasil. A excepcional precisão do ERA5-LAND na representação dos processos atmosféricos pode ser justificada pela sua capacidade de integrar uma extensa gama de observações meteorológicas,

incluindo dados de satélites, estações meteorológicas e sondagens atmosféricas (XU et al., 2022).

Por contraste, o NCEP/DOE apresentou desempenho inferior, especialmente na escala diária e no contexto do bioma Amazônia, conforme indicado por coeficientes de correlação mais baixos. Essa discrepância é consistente com estudos anteriores que apontam para possíveis erros significativos do NCEP/DOE na estimativa da umidade relativa em comparação com as observações. A resolução espacial limitada do NCEP/DOE, a qual é inferior aos demais produtos avaliados, geralmente resulta em uma subutilização das informações mais detalhadas da superfície, levando a falhas em capturar dados mais pontuais (PEDREIRA JUNIOR et al., 2021).

O Sistema Global de Assimilação de Dados Terrestres (GLDAS) aplica dados observados e de satélite como insumos na modelagem de superfície para gerar variáveis associadas aos componentes hidrológicos nos continentes (RODELL et al., 2004). Os modelos GLDAS são construídos usando dados de precipitação observada, produtos de radiação incidente e a melhor assimilação de dados atmosféricos disponível (CHEN et al., 2013). Embora seja uma fonte de dados importante para a pesquisa do ciclo global da água, teve o desempenho mais baixo nas estimativas de umidade relativa do ar mensal e anual e para os biomas Cerrado, Pantanal e Mata Atlântica, e na estimativa do déficit de pressão de vapor para o Pantanal. Isso pode ser atribuído à dificuldade do GLDAS em capturar variações sazonais na mudança do armazenamento de água terrestre observada.

O JRA55, uma reanálise de terceira geração reconhecida por sua longa duração e resolução, também é amplamente empregado em aplicações climáticas e meteorológicas (JRA-55; KOBAYASHI et al., 2015). Contudo, para a região Centro-Oeste, apresentou o pior desempenho nas estimativas de déficit de pressão de vapor em todas as escalas, e para os biomas Amazônia, Cerrado e Mata Atlântica. Esses resultados indicam que, apesar das qualidades globais do JRA55, sua precisão específica pode variar consideravelmente dependendo da variável em estudo e da região geográfica analisada.

Em uma análise abrangente das estimativas dos produtos de reanálise, observamos que as fontes de erro estão intrinsecamente relacionadas aos parâmetros de entrada desses modelos, conforme discutido por Zhou e Du (2016). A escolha dos parâmetros e suas interações podem influenciar diretamente a qualidade das estimativas, destacando a importância de uma cuidadosa seleção e sintonia desses elementos nos processos de reanálise. Além disso, as diferenças nos métodos de cálculo da média de reanálise, nos processos de assimilação de dados

e nos níveis verticais considerados também emergem como fatores contribuintes para os erros nas análises, corroborando as descobertas de Hu et al. (2019).

É crucial notar que a qualidade dos resultados obtidos está intrinsecamente ligada à qualidade intrínseca dos produtos de reanálise em relação às variáveis específicas, como umidade relativa do ar e déficit de pressão de vapor (MARTINS et al., 2015). A confiança nos resultados dependerá, portanto, da precisão e da capacidade dos produtos de reanálise em representar essas variáveis essenciais de maneira realista e coerente com as condições observadas. Ademais, é importante reconhecer que os produtos de reanálise incorporam elementos preditivos em suas estimativas, uma vez que processam informações provenientes de métodos de previsão (PARKER et al.; 2016). Essa componente preditiva é inerente ao processo de reanálise e, embora ofereça uma perspectiva valiosa, deve ser considerada ao interpretar e comparar resultados com observações in loco, que carecem desse componente preditivo. As equações que compõem a dinâmica dos modelos numéricos de previsão e os métodos de assimilação variacional empregados na produção das estimativas introduzem complexidades na composição dos produtos de reanálise, influenciando diretamente a qualidade e a confiabilidade dos resultados obtidos, conforme destacado por Parker et al. (2016).

5. CONCLUSÃO

A análise comparativa de diferentes produtos de temperatura do ar, umidade relativa do ar e déficit de pressão de vapor na região Centro-Oeste do Brasil revelou a importância de considerar múltiplos conjuntos de dados e variáveis climatológicas para obter uma compreensão abrangente das estimativas climáticas. Recomenda-se o uso combinado de diferentes fontes de dados e a consideração das características específicas de cada região para uma análise mais completa e confiável do clima.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ABDELMONEIM, H., SOLIMAN, M. R., & MOGHAZY, H. M. (2022). Hydrologic Assessment of the Uncertainty of Six Remote Sensing Precipitation Estimates Driven by a Distributed Hydrologic Model in the Blue Nile Basin. Em T. Sumi, S. A. Kantoush, & M. Saber (Orgs.), *Wadi Flash Floods: Challenges and Advanced Approaches for Disaster Risk Reduction* (p. 225–249). **Springer**. https://doi.org/10.1007/978-981-16-2904-4_8

AGUTU, N. O., AWANGE, J. L., ZERIHUN, A., NDEHEDEHE, C. E., KUHN, M., & FUKUDA, Y. (2017). Assessing multi-satellite remote sensing, reanalysis, and land surface

models' products in characterizing agricultural drought in East Africa. **Remote Sensing of Environment**, 194, 287–302. <https://doi.org/10.1016/j.rse.2017.03.041>

ALESHINA, M. A., SEMENOV, V. A., & CHERNOKULSKY, A. V. (2021). A link between surface air temperature and extreme precipitation over Russia from station and reanalysis data. **Environmental Research Letters**, 16(10), 105004. <https://doi.org/10.1088/1748-9326/ac1cba>

ALMAGRO, A., OLIVEIRA, P. T. S., & BROCCA, L. (2021). Assessment of bottom-up satellite rainfall products on estimating river discharge and hydrologic signatures in Brazilian catchments. **Journal of Hydrology**, 603, 126897. <https://doi.org/10.1016/j.jhydrol.2021.126897>

ALMAZROUI, M., ASHFAQ, M., ISLAM, M. N., RASHID, I. U., KAMIL, S., ABID, M. A., O'BRIEN, E., ISMAIL, M., REBOITA, M. S., SÖRENSON, A. A., ARIAS, P. A., ALVES, L. M., TIPPETT, M. K., SAEED, S., HAARSMA, R., DOBLAS-REYES, F. J., SAEED, F., KUCHARSKI, F., NADEEM, I., ... SYLLA, M. B. (2021). Assessment of CMIP6 Performance and Projected Temperature and Precipitation Changes Over South America. **Earth Systems and Environment**, 5(2), 155–183. <https://doi.org/10.1007/s41748-021-00233-6>

ALVARES, C. A., STAPE, J. L., SENTELHAS, P. C., DE MORAES GONÇALVES, J. L., & SPAROVEK, G. (2013). Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, 711–728. <https://doi.org/10.1127/0941-2948/2013/0507>

ARAGHI, A., MARTINEZ, C. J., OLESEN, J. E., & HOOGENBOOM, G. (2022). Assessment of nine gridded temperature data for modeling of wheat production systems. **Computers and Electronics in Agriculture**, 199, 107189. <https://doi.org/10.1016/j.compag.2022.107189>

ARAÚJO, C. S. P. DE, SILVA, I. A. C. E, IPPOLITO, M., & ALMEIDA, C. D. G. C. de. (2022). Evaluation of air temperature estimated by ERA5-Land reanalysis using surface data in Pernambuco, Brazil. **Environmental Monitoring and Assessment**, 194(5), 381. <https://doi.org/10.1007/s10661-022-10047-2>

AVILA-DIAZ, A., ABRAHÃO, G., JUSTINO, F., TORRES, R., & WILSON, A. (2020). Extreme climate indices in Brazil: Evaluation of downscaled earth system models at high horizontal resolution. **Climate Dynamics**, 54(11), 5065–5088. <https://doi.org/10.1007/s00382-020-05272-9>

BAN, N., CAILLAUD, C., COPPOLA, E., PICHELLI, E., SOBOLOWSKI, S., ADINOLFI, M., AHRENS, B., ALIAS, A., ANDERS, I., BASTIN, S., BELUŠIĆ, D., BERTHOU, S., BRISSON, E., CARDOSO, R. M., CHAN, S. C., CHRISTENSEN, O. B., FERNÁNDEZ, J., FITA, L., FRISIUS, T., ... ZANDER, M. J. (2021). THE FIRST MULTI-model ensemble of regional climate simulations at kilometer-scale resolution, part I: Evaluation of precipitation. **Climate Dynamics**, 57(1), 275–302. <https://doi.org/10.1007/s00382-021-05708-w>

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(11), 2147–2161. <https://doi.org/10.1175/JHM-D-19-0073.1>

- CHEN, S., GAN, T. Y., TAN, X., SHAO, D., & ZHU, J. (2019). Assessment of CFSR, ERA-Interim, JRA-55, MERRA-2, NCEP-2 reanalysis data for drought analysis over China. **Climate Dynamics**, 53(1), 737–757. <https://doi.org/10.1007/s00382-018-04611-1>
- DE MORAES, R. B. F., & GONÇALVES, F. V. (2023). Comparison of the performance of estimated precipitation data via remote sensing in the Midwest Region of Brazil. **Theoretical and Applied Climatology**. <https://doi.org/10.1007/s00704-023-04523-z>
- DERIN, Y., ANAGNOSTOU, E., BERNE, A., BORGA, M., BOUDEVILLAIN, B., BUYTAERT, W., CHANG, C.-H., DELRIEU, G., HONG, Y., HSU, Y. C., LAVADO-CASIMIRO, W., MANZ, B., MOGES, S., NIKOLOPOULOS, E. I., SAHLU, D., SALERNO, F., RODRÍGUEZ-SÁNCHEZ, J.-P., VERGARA, H. J., & YILMAZ, K. K. (2016). Multiregional Satellite Precipitation Products Evaluation over Complex Terrain. **Journal of Hydrometeorology**, 17(6), 1817–1836. <https://doi.org/10.1175/JHM-D-15-0197.1>
- FASSONI-ANDRADE, A. C., FLEISCHMANN, A. S., PAPA, F., PAIVA, R. C. D. DE, WONGCHUIG, S., MELACK, J. M., MOREIRA, A. A., PARIS, A., RUHOFF, A., BARBOSA, C., MACIEL, D. A., NOVO, E., DURAND, F., FRAPPART, F., AIRES, F., ABRAHÃO, G. M., FERREIRA-FERREIRA, J., ESPINOZA, J. C., LAIPELT, L., ... PELLET, V. (2021). Amazon Hydrology From Space: Scientific Advances and Future Challenges. **Reviews of Geophysics**, 59(4), e2020RG000728. <https://doi.org/10.1029/2020RG000728>
- FUNK, C., PETERSON, P., LANDSFELD, M., PEDREROS, D., VERDIN, J., SHUKLA, S., HUSAK, G., ROWLAND, J., HARRISON, L., HOELL, A., & MICHAELSEN, J. (2015). The climate hazards infrared precipitation with stations—A new environmental record for monitoring extremes. **Scientific Data**, 2(1), Artigo 1. <https://doi.org/10.1038/sdata.2015.66>
- GELARO, R., MCCARTY, W., SUÁREZ, M. J., TODLING, R., MOLOD, A., TAKACS, L., RANGLES, C. A., DARMENOV, A., BOSILOVICH, M. G., REICHLER, R., WARGAN, K., COY, L., CULLATHER, R., DRAPER, C., AKELLA, S., BUCHARD, V., CONATY, A., SILVA, A. M. DA, GU, W., ... ZHAO, B. (2017). The Modern-Era Retrospective Analysis for Research and Applications, Version 2 (MERRA-2). **Journal of Climate**, 30(14), 5419–5454. <https://doi.org/10.1175/JCLI-D-16-0758.1>
- HESSLEROVÁ, P., POKORNÝ, J., HURYNA, H., & HARPER, D. (2019). Wetlands and Forests Regulate Climate via Evapotranspiration. Em S. An & J. T. A. Verhoeven (Orgs.), *Wetlands: Ecosystem Services, Restoration and Wise Use* (p. 63–93). **Springer International Publishing**. https://doi.org/10.1007/978-3-030-14861-4_4
- HOBOUCHIAN, M. P., SALIO, P., GARCÍA SKABAR, Y., VILA, D., & GARREAUD, R. (2017). Assessment of satellite precipitation estimates over the slopes of the subtropical Andes. **Atmospheric Research**, 190, 43–54. <https://doi.org/10.1016/j.atmosres.2017.02.006>
- HUFFMAN, G. J., BEHRANGI, A., ADLER, R. F., BOLVIN, D. T., NELKIN, E. J., SONG, Y., & WANG, J.-J. (2021). **The Global Precipitation Climatology Project Version 3 Products**. EGU21-8468. <https://doi.org/10.5194/egusphere-egu21-8468>
- HUFFMAN, G. J., BOLVIN, D. T., NELKIN, E. J., WOLFF, D. B., ADLER, R. F., GU, G., HONG, Y., BOWMAN, K. P., & STOCKER, E. F. (2007). The TRMM Multisatellite

- Precipitation Analysis (TMPA): Quasi-Global, Multiyear, Combined-Sensor Precipitation Estimates at Fine Scales. **Journal of Hydrometeorology**, 8(1), 38–55. <https://doi.org/10.1175/JHM560.1>
- JUNIOR, A. L. P., BIUDES, M. S., MACHADO, N. G., VOURLITIS, G. L., GELI, H. M. E., SANTOS, L. O. F. DOS, 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(3), Artigo 3. <https://doi.org/10.3390/w13030333>
- KOBAYASHI, S., OTA, Y., HARADA, Y., EBITA, A., MORIYA, M., ONODA, H., ONOGI, K., KAMAHORI, H., KOBAYASHI, C., ENDO, H., MIYAOKA, K., & TAKAHASHI, K. (2015). THE JRA-55 REANALYSIS: General Specifications and Basic Characteristics. **気象集誌. 第2輯**, 93(1), 5–48. <https://doi.org/10.2151/jmsj.2015-001>
- LIEBMANN, B., & MECHOSO, C. R. (2011). The south american monsoon system. Em *The Global Monsoon System: Vol. Volume 5* (p. 137–157). **WORLD SCIENTIFIC**. https://doi.org/10.1142/9789814343411_0009
- LIRA, B. R. P., FERNANDES, L. L., & ISHIHARA, J. H. (2022). Pluviometric behavior and trends in the Legal Amazon from 1986 to 2015. **Theoretical and Applied Climatology**, 150(3), 1353–1367. <https://doi.org/10.1007/s00704-022-04200-7>
- LIU, L., GU, H., XIE, J., & XU, Y.-P. (2021). How well do the ERA-Interim, ERA-5, GLDAS-2.1 and NCEP-R2 reanalysis datasets represent daily air temperature over the Tibetan Plateau? **International Journal of Climatology**, 41(2), 1484–1505. <https://doi.org/10.1002/joc.6867>
- MACHADO, N. G., BIUDES, M. S., QUERINO, C. A. S., DANELICHEN, V. H. DE M., & VELASQUE, M. C. S. (2015). Seasonal and interannual pattern of meteorological variables in Cuiabá, Mato Grosso state, **Brazil. Revista Brasileira de Geofísica**, 33(3), 477–488. <https://doi.org/10.22564/rbgf.v33i3.748>
- MANZANAS, R., GUTIÉRREZ, J. M., BHEND, J., HEMRI, S., DOBLAS-REYES, F. J., TORRALBA, V., PENABAD, E., & BROOKSHAW, A. (2019). Bias adjustment and ensemble recalibration methods for seasonal forecasting: A comprehensive intercomparison using the C3S dataset. **Climate Dynamics**, 53(3), 1287–1305. <https://doi.org/10.1007/s00382-019-04640-4>
- MELLO, K. DE, TANIWAKI, R. H., PAULA, F. R. DE, VALENTE, R. A., RANDHIR, T. O., MACEDO, D. R., LEAL, C. G., RODRIGUES, C. B., & HUGHES, R. M. (2020). Multiscale land use impacts on water quality: Assessment, planning, and future perspectives in Brazil. **Journal of Environmental Management**, 270, 110879. <https://doi.org/10.1016/j.jenvman.2020.110879>
- MORICE, C. P., KENNEDY, J. J., RAYNER, N. A., WINN, J. P., HOGAN, E., KILLICK, R. E., DUNN, R. J. H., OSBORN, T. J., JONES, P. D., & SIMPSON, I. R. (2021). An Updated Assessment of Near-Surface Temperature Change From 1850: The HadCRUT5 Data Set. **Journal of Geophysical Research: Atmospheres**, 126(3), e2019JD032361. <https://doi.org/10.1029/2019JD032361>

- MUÑOZ-SABATER, J., DUTRA, E., AGUSTÍ-PANAREDA, A., ALBERGEL, C., ARDUINI, G., BALSAMO, G., BOUSSETTA, S., CHOULGA, M., HARRIGAN, S., HERSBACH, H., MARTENS, B., MIRALLES, D. G., PILES, M., RODRÍGUEZ-FERNÁNDEZ, N. J., ZSOTER, E., BUONTEMPO, C., & THÉPAUT, J.-N. (2021). ERA5-Land: A state-of-the-art global reanalysis dataset for land applications. **Earth System Science Data**, 13(9), 4349–4383. <https://doi.org/10.5194/essd-13-4349-2021>
- NADEEM, M. U., GHANIM, A. A. J., ANJUM, M. N., SHANGGUAN, D., RASOOL, G., IRFAN, M., NIAZI, U. M., & HASSAN, S. (2022). Multiscale Ground Validation of Satellite and Reanalysis Precipitation Products over Diverse Climatic and Topographic Conditions. **Remote Sensing**, 14(18), Artigo 18. <https://doi.org/10.3390/rs14184680>
- PENG, X., SHE, J., ZHANG, S., TAN, J., & LI, Y. (2019). Evaluation of Multi-Reanalysis Solar Radiation Products Using Global Surface Observations. **Atmosphere**, 10(2), Artigo 2. <https://doi.org/10.3390/atmos10020042>
- QUANSAH, A. D., DOGBEY, F., ASILEVI, P. J., BOAKYE, P., DARKWAH, L., ODURO-KWARTENG, S., SOKAMA-NEUYAM, Y. A., & MENSAH, P. (2022). Assessment of solar radiation resource from the NASA-POWER reanalysis products for tropical climates in Ghana towards clean energy application. **Scientific Reports**, 12(1), Artigo 1. <https://doi.org/10.1038/s41598-022-14126-9>
- RANGLES, C. A., SILVA, A. M. DA, BUCHARD, V., COLARCO, P. R., DARMENOV, A., GOVINDARAJU, R., SMIRNOV, A., HOLBEN, B., FERRARE, R., HAIR, J., SHINOZUKA, Y., & FLYNN, C. J. (2017). The MERRA-2 Aerosol Reanalysis, 1980 Onward. Part I: System Description and Data Assimilation Evaluation. **Journal of Climate**, 30(17), 6823–6850. <https://doi.org/10.1175/JCLI-D-16-0609.1>
- SALEHIE, O., ISMAIL, T. BIN, SHAHID, S., SAMMEN, S. S., MALIK, A., & WANG, X. (2022). Selection of the gridded temperature dataset for assessment of thermal bioclimatic environmental changes in Amu Darya River basin. **Stochastic Environmental Research and Risk Assessment**, 36(9), 2919–2939. <https://doi.org/10.1007/s00477-022-02172-8>
- SKOFRONICK-JACKSON, G., PETERSEN, W. A., BERG, W., KIDD, C., STOCKER, E. F., KIRSCHBAUM, D. B., KAKAR, R., BRAUN, S. A., HUFFMAN, G. J., IGUCHI, T., KIRSTETTER, P. E., KUMMEROW, C., MENEGHINI, R., OKI, R., OLSON, W. S., TAKAYABU, Y. N., FURUKAWA, K., & WILHEIT, T. (2017). The Global Precipitation Measurement (GPM) Mission for Science and Society. **Bulletin of the American Meteorological Society**, 98(8), 1679–1695. <https://doi.org/10.1175/BAMS-D-15-00306.1>
- SUN, Q., MIAO, C., DUAN, Q., ASHOURI, H., SOROOSHIAN, S., & HSU, K.-L. (2018). A Review of Global Precipitation Data Sets: Data Sources, Estimation, and Intercomparisons. **Reviews of Geophysics**, 56(1), 79–107. <https://doi.org/10.1002/2017RG000574>
- TAN, M. L., & DUAN, Z. (2017). Assessment of GPM and TRMM Precipitation Products over Singapore. **Remote Sensing**, 9(7), Artigo 7. <https://doi.org/10.3390/rs9070720>
- TAREK, M., BRISSETTE, F. P., & ARSENAULT, R. (2020). Evaluation of the ERA5 reanalysis as a potential reference dataset for hydrological modelling over North America.

Hydrology and Earth System Sciences, 24(5), 2527–2544. <https://doi.org/10.5194/hess-24-2527-2020>

XU, J., MA, Z., YAN, S., & PENG, J. (2022). Do ERA5 and ERA5-Land precipitation estimates outperform satellite-based precipitation products? A comprehensive comparison between state-of-the-art model-based and satellite-based precipitation products over mainland China. **Journal of Hydrology**, 605, 127353. <https://doi.org/10.1016/j.jhydrol.2021.127353>

7. ANEXOS

Temperatura do ar máxima, média e mínima

TABELA 9 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da temperatura do ar máxima ($T_{ar\max}$) nas escalas diária, mensal e anual pelos produtos CPC, ERA5-LAND, GLDAS, JRA55, MERRA-2, NCEP/DOE e ENSEMBLE para a região Centro-Oeste do Brasil.

Escala	Produtos	Média \pm IC ($^{\circ}$ C)	MAE	RMSE	d	r	ρ_c	Pbias
Diária	Medido	29.99 \pm 0.10	-	-	-	-	-	-
	CPC	30.58 \pm 0.10	1.6	2.31	0.9	0.81	0.81	1.16
	ERA5-LAND	28.77 \pm 0.10	1.84	2.19	0.91	0.89	0.82	-5.1
	GLDAS	28.39 \pm 0.13	2.19	2.74	0.88	0.81	0.77	-4.66
	JRA55	28.38 \pm 0.11	2.73	3.32	0.8	0.73	0.65	-8.1
	MERRA-2	30.25 \pm 0.12	2.08	2.59	0.88	0.73	0.77	-0.54
	NCEP/DOE	28.16 \pm 0.14	3.76	4.47	0.71	0.63	0.5	-11.55
	ENSEMBLE	29.09 \pm 0.11	1.8	2.15	0.91	0.88	0.83	-4.62
Mensal	Medido	29.93 \pm 0.31	-	-	-	-	-	-
	CPC	30.53 \pm 0.27	1.15	1.54	0.86	0.75	0.75	1.12
	ERA5-LAND	28.73 \pm 0.29	1.53	1.7	0.85	0.92	0.73	-5.09
	GLDAS	28.35 \pm 0.40	1.67	2.04	0.84	0.83	0.7	-4.73
	JRA55	28.36 \pm 0.30	2.43	2.84	0.65	0.65	0.42	-8.14
	MERRA-2	30.20 \pm 0.37	1.4	1.75	0.85	0.71	0.72	-0.54
	NCEP/DOE	28.17 \pm 0.49	3.4	3.95	0.55	0.49	0.25	-11.62
	ENSEMBLE	29.05 \pm 0.31	1.51	1.73	0.84	0.87	0.71	-4.66
Anual	Medido	29.93 \pm 0.76	-	-	-	-	-	-
	CPC	30.53 \pm 0.62	1.05	1.39	0.83	0.72	0.69	1.11
	ERA5-LAND	28.72 \pm 0.54	1.52	1.64	0.8	0.93	0.65	-5.09
	GLDAS	28.34 \pm 0.81	1.57	1.88	0.79	0.82	0.63	-4.77
	JRA55	28.36 \pm 0.45	2.4	2.76	0.53	0.54	0.25	-8.12
	MERRA-2	30.21 \pm 0.63	1.19	1.5	0.81	0.65	0.65	-0.58
	NCEP/DOE	28.18 \pm 1.18	3.33	3.84	0.45	0.35	0.12	-11.53
	ENSEMBLE	29.05 \pm 0.45	1.47	1.66	0.76	0.86	0.6	-4.66

TABELA 10 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da temperatura do ar máxima (Tarmáx).

Escala	Bioma	Produtos	Média \pm IC ($^{\circ}$ C)	MAE	RMSE	d	r	ρ_c	Pbias
Diária	Amazônia	Medido	32.09 \pm 0.12	-	-	-	-	-	-
		CPC	32.48 \pm 0.13	1.65	2.41	2.41	0.76	0.73	0.89
		ERA5-LAND	30.48 \pm 0.12	2.02	2.43	2.43	0.83	0.71	-5.6
		GLDAS	31.00 \pm 0.17	2.1	2.74	2.74	0.75	0.7	-2.75
		JRA55	28.73 \pm 0.13	4.02	4.59	4.59	0.6	0.36	-13.43
		MERRA-2	31.22 \pm 0.16	2.55	3.1	3.1	0.66	0.62	-3.62
		NCEP/DOE	28.68 \pm 0.15	4.18	4.79	4.79	0.62	0.36	-13.77
		ENSEMBLE	30.43 \pm 0.13	2.14	2.53	2.53	0.83	0.69	-6.11
	Cerrado	Medido	30.54 \pm 0.11	-	-	-	-	-	-
		CPC	31.14 \pm 0.11	1.62	2.29	0.89	0.8	0.8	1.72
		ERA5-LAND	29.16 \pm 0.10	1.8	2.14	0.9	0.89	0.82	-5.13
		GLDAS	28.91 \pm 0.13	2.19	2.72	0.87	0.81	0.76	-5.18
		JRA55	28.83 \pm 0.11	2.41	2.93	0.83	0.77	0.69	-6.8
		MERRA-2	30.59 \pm 0.12	1.98	2.47	0.88	0.74	0.77	-0.11
		NCEP/DOE	28.38 \pm 0.15	3.6	4.32	0.71	0.61	0.49	-10.67
		ENSEMBLE	29.50 \pm 0.11	1.69	2.04	0.91	0.88	0.83	-4.2
	Pantanal	Medido	32.22 \pm 0.24	-	-	-	-	-	-
		CPC	32.34 \pm 0.19	2.05	3.21	0.86	0.66	0.73	0.3
		ERA5-LAND	31.14 \pm 0.22	1.63	1.95	0.95	0.91	0.9	-3.54
		GLDAS	31.83 \pm 0.26	2.16	2.75	0.91	0.78	0.83	-1.06
		JRA55	29.89 \pm 0.22	2.87	3.53	0.85	0.77	0.72	-8.01
		MERRA-2	33.85 \pm 0.23	2.39	2.96	0.89	0.81	0.8	4.85
		NCEP/DOE	28.73 \pm 0.25	4.11	4.8	0.77	0.72	0.59	-12.5
		ENSEMBLE	31.30 \pm 0.21	1.67	2.01	0.94	0.89	0.89	-3.03
	Mata Atlântica	Medido	30.46 \pm 0.19	-	-	-	-	-	-
		CPC	30.17 \pm 0.19	1.3	1.89	0.95	0.9	0.91	-1.34
		ERA5-LAND	29.12 \pm 0.17	1.8	2.13	0.94	0.91	0.88	-4.65
		GLDAS	28.57 \pm 0.18	2.32	2.83	0.9	0.84	0.81	-6.04
JRA55		28.40 \pm 0.18	2.56	3.03	0.88	0.85	0.78	-7.61	
MERRA-2		30.42 \pm 0.18	1.8	2.3	0.93	0.82	0.87	-0.19	
NCEP/DOE		27.41 \pm 0.19	3.94	4.66	0.76	0.71	0.58	-12.76	
ENSEMBLE		29.02 \pm 0.17	1.89	2.21	0.93	0.92	0.87	-5.27	
Mensal	Amazônia	Medido	32.07 \pm 0.31	-	-	-	-	-	-
		CPC	32.47 \pm 0.32	1.03	1.33	0.83	0.68	0.69	0.86
		ERA5-LAND	30.46 \pm 0.34	1.73	1.92	0.73	0.85	0.54	-5.61
		GLDAS	30.97 \pm 0.55	1.4	1.82	0.8	0.79	0.64	-3.06
		JRA55	28.73 \pm 0.39	3.85	4.21	0.44	0.42	0.13	-13.45
		MERRA-2	31.20 \pm 0.55	1.84	2.22	0.72	0.62	0.5	-3.7

		NCEP/DOE	28.68	± 0.52	3.92	4.32	0.48	0.48	0.15	-13.74
		ENSEMBLE	30.66	± 0.36	1.91	2.14	0.7	0.79	0.48	-6.18
	Cerrado	Medido	30.47	± 0.33	-	-	-	-	-	-
		CPC	31.08	± 0.29	1.24	1.63	0.85	0.74	0.72	1.67
		ERA5-LAND	29.11	± 0.30	1.53	1.69	0.85	0.93	0.74	-5.11
		GLDAS	28.86	± 0.41	1.72	2.08	0.83	0.83	0.68	-5.2
		JRA55	28.79	± 0.31	2.1	2.43	0.71	0.75	0.51	-6.83
		MERRA-2	30.54	± 0.39	1.33	1.66	0.86	0.73	0.74	-0.1
		NCEP/DOE	28.38	± 0.50	3.23	3.82	0.55	0.45	0.25	-10.79
		ENSEMBLE	29.60	± 0.32	1.41	1.63	0.85	0.88	0.73	-4.23
	Pantanal	Medido	32.19	± 0.51	-	-	-	-	-	-
		CPC	32.29	± 0.39	1.32	2.03	0.74	0.56	0.54	0.48
		ERA5-LAND	31.12	± 0.48	1.18	1.34	0.88	0.92	0.79	-3.66
		GLDAS	31.75	± 0.67	1.55	1.9	0.81	0.67	0.66	-1.13
		JRA55	29.94	± 0.49	2.38	2.81	0.65	0.68	0.41	-7.79
		MERRA-2	33.87	± 0.57	1.85	2.16	0.78	0.8	0.61	4.98
		NCEP/DOE	28.83	± 0.65	3.65	4.12	0.55	0.57	0.26	-12.5
		ENSEMBLE	31.43	± 0.47	1.17	1.35	0.87	0.86	0.77	-2.96
	Mata Atlântica	Medido	30.62	± 0.42	-	-	-	-	-	-
		CPC	30.40	± 0.43	0.75	1.02	0.93	0.9	0.88	-1.35
		ERA5-LAND	29.21	± 0.39	1.38	1.51	0.88	0.94	0.78	-4.65
		GLDAS	28.67	± 0.47	1.86	2.16	0.8	0.82	0.64	-6.18
		JRA55	28.58	± 0.45	2.16	2.33	0.76	0.89	0.59	-7.58
		MERRA-2	30.53	± 0.48	0.99	1.21	0.93	0.85	0.86	-0.16
		NCEP/DOE	27.67	± 0.59	3.47	4	0.57	0.59	0.3	-12.66
		ENSEMBLE	29.39	± 0.42	1.55	1.71	0.85	0.92	0.73	-5.27
Anual	Amazônia	Medido	32.01	± 0.59	-	-	-	-	-	-
		CPC	32.34	± 0.69	0.88	1.11	0.76	0.44	0.57	0.82
		ERA5-LAND	30.37	± 0.60	1.72	1.84	0.57	0.76	0.34	-5.63
		GLDAS	30.80	± 1.26	1.16	1.51	0.72	0.7	0.53	-3.1
		JRA55	28.66	± 0.77	3.82	4.14	0.32	0.11	0.01	-13.45
		MERRA-2	31.01	± 1.15	1.6	1.91	0.59	0.44	0.3	-3.76
		NCEP/DOE	28.70	± 1.12	3.89	4.23	0.37	0.26	0.04	-13.71
		ENSEMBLE	30.32	± 0.62	1.89	2.06	0.5	0.63	0.25	-6.2
	Cerrado	Medido	30.47	± 0.81	-	-	-	-	-	-
		CPC	31.09	± 0.69	1.18	1.52	0.81	0.68	0.66	1.66
		ERA5-LAND	29.12	± 0.57	1.51	1.63	0.81	0.94	0.67	-5.11
		GLDAS	28.88	± 0.82	1.65	1.95	0.78	0.82	0.62	-5.26
		JRA55	28.79	± 0.51	2.07	2.34	0.61	0.71	0.37	-6.81
		MERRA-2	30.56	± 0.64	1.13	1.43	0.83	0.69	0.69	-0.15
		NCEP/DOE	28.39	± 1.21	3.15	3.71	0.46	0.32	0.12	-10.66
		ENSEMBLE	29.47	± 0.50	1.37	1.55	0.79	0.88	0.64	-4.23

Pantanal	Medido	32.25	± 0.73	-	-	-	-	-	-
	CPC	32.33	± 0.51	1.13	1.67	0.6	0.44	0.34	0.37
	ERA5-LAND	31.19	± 0.75	1.14	1.22	0.72	0.84	0.55	-3.63
	GLDAS	31.81	± 1.41	1.42	1.67	0.56	0.26	0.27	-1.1
	JRA55	29.98	± 0.87	2.34	2.72	0.46	0.35	0.1	-7.77
	MERRA-2	33.92	± 1.01	1.72	1.93	0.62	0.68	0.37	4.93
	NCEP/DOE	28.89	± 1.69	3.6	4	0.41	0.31	0.06	-12.48
	ENSEMBLE	31.34	± 0.68	1.08	1.23	0.69	0.63	0.48	-2.98
Mata Atlântica	Medido	30.62	± 0.63	-	-	-	-	-	-
	CPC	30.41	± 0.87	0.59	0.79	0.9	0.88	0.82	-1.34
	ERA5-LAND	29.23	± 0.60	1.36	1.43	0.76	0.95	0.61	-4.68
	GLDAS	28.68	± 0.88	1.8	2.03	0.65	0.75	0.42	-6.17
	JRA55	28.61	± 0.87	2.14	2.24	0.57	0.88	0.34	-7.54
	MERRA-2	30.55	± 0.89	0.76	0.94	0.9	0.83	0.81	-0.11
	NCEP/DOE	27.68	± 1.48	3.44	3.89	0.44	0.33	0.09	-12.67
	ENSEMBLE	29.20	± 0.79	1.53	1.64	0.7	0.89	0.51	-5.26

TABELA 11 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da temperatura do ar média ($T_{ar_{méd}}$) nas escalas diária, mensal e anual pelos produtos CPC, ERA5-LAND, GLDAS, JRA55, MERRA-2, NCEP/DOE e ENSEMBLE para a região Centro-Oeste do Brasil.

Escala	Produtos	Média \pm IC ($^{\circ}$ C)	MAE	RMSE	d	r	ρ_c	Pbias
Diária	Medido	18.37 \pm 0.11	-	-	-	-	-	-
	CPC	19.32 \pm 0.11	1.86	2.41	0.85	0.81	0.73	6.14
	ERA5-LAND	19.49 \pm 0.09	0.93	1.23	0.96	0.9	0.92	1.52
	GLDAS	18.53 \pm 0.1	1.28	1.61	0.93	0.84	0.87	-1.42
	JRA55	20.8 \pm 0.08	1.71	2.18	0.87	0.77	0.76	4.91
	MERRA-2	18.67 \pm 0.11	1.4	1.82	0.91	0.82	0.84	2.62
	NCEP/DOE	20.15 \pm 0.11	1.43	1.8	0.9	0.77	0.81	-1.55
	ENSEMBLE	19.49 \pm 0.09	0.97	1.29	0.95	0.9	0.91	2.13
Mensal	Medido	18.34 \pm 0.35	-	-	-	-	-	-
	CPC	19.28 \pm 0.36	1.64	1.97	0.77	0.8	0.6	6.09
	ERA5-LAND	19.44 \pm 0.31	0.57	0.76	0.96	0.93	0.92	1.49
	GLDAS	18.49 \pm 0.33	0.87	1.09	0.92	0.86	0.86	-1.45
	JRA55	20.76 \pm 0.25	1.39	1.68	0.8	0.76	0.65	4.71
	MERRA-2	18.62 \pm 0.38	1.01	1.33	0.89	0.83	0.8	2.65
	NCEP/DOE	20.11 \pm 0.37	1.01	1.24	0.87	0.77	0.76	-1.62
	ENSEMBLE	19.45 \pm 0.32	0.69	0.91	0.94	0.91	0.88	2.06
Anual	Medido	18.34 \pm 0.5	-	-	-	-	-	-
	CPC	19.27 \pm 0.6	1.61	1.88	0.72	0.78	0.51	6.1
	ERA5-LAND	19.44 \pm 0.56	0.5	0.63	0.96	0.94	0.92	1.49
	GLDAS	18.47 \pm 0.65	0.75	0.94	0.91	0.86	0.84	-1.47

JRA55	20.76	±	0.56	1.34	1.57	0.72	0.73	0.54	4.72
MERRA-2	18.63	±	0.66	0.9	1.19	0.87	0.82	0.76	2.64
NCEP/DOE	20.13	±	0.76	0.93	1.13	0.8	0.74	0.65	-1.58
ENSEMBLE	19.44	±	0.6	0.63	0.83	0.92	0.91	0.84	2.07

TABELA 12 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da temperatura do ar média (Tarméd).

Escala	Bioma	Produtos	Média \pm IC ($^{\circ}$ C)		MAE	RMSE	d	r	ρ_c	Pbias	
Diária	Amazônia	Medido	25.1	±	0.07	-	-	-	-	-	-
		CPC	26.76	±	0.09	1.98	2.48	0.72	0.67	0.52	6.14
		ERA5-LAND	25.5	±	0.07	1.03	1.4	0.87	0.73	0.76	1.5
		GLDAS	24.93	±	0.09	1.23	1.61	0.85	0.69	0.73	-0.48
		JRA55	25.85	±	0.09	1.5	2.02	0.77	0.54	0.6	1.98
		MERRA 2	25.96	±	0.1	1.53	2.02	0.78	0.6	0.62	2.94
		NCEP/DOE	24.62	±	0.08	1.35	1.72	0.81	0.61	0.66	-2.28
		ENSEMBLE	25.6	±	0.08	0.98	1.35	0.88	0.75	0.78	1.7
	Cerrado	Medido	23.76	±	0.09	-	-	-	-	-	-
		CPC	25.4	±	0.09	1.91	2.45	0.83	0.81	0.7	6.52
		ERA5-LAND	24.11	±	0.08	0.89	1.16	0.96	0.91	0.92	1.44
		GLDAS	23.23	±	0.1	1.27	1.6	0.93	0.84	0.86	-1.57
		JRA55	25.3	±	0.09	1.8	2.26	0.86	0.79	0.74	5.77
		MERRA 2	24.34	±	0.1	1.37	1.77	0.91	0.82	0.83	2.63
		NCEP/DOE	23.63	±	0.1	1.42	1.79	0.89	0.76	0.8	-0.97
		ENSEMBLE	24.33	±	0.09	0.99	1.3	0.95	0.9	0.9	2.4
	Pantanal	Medido	25.69	±	0.2	-	-	-	-	-	-
		CPC	26.82	±	0.16	1.96	2.9	0.85	0.67	0.73	4.27
		ERA5-LAND	26.25	±	0.19	1.04	1.37	0.97	0.91	0.94	2.04
		GLDAS	25.67	±	0.21	1.5	1.85	0.94	0.83	0.89	0.05
		JRA55	26.6	±	0.19	1.61	2.08	0.92	0.81	0.86	3.27
		MERRA 2	27.18	±	0.2	1.89	2.34	0.92	0.85	0.84	5.52
		NCEP/DOE	24.52	±	0.2	1.79	2.17	0.92	0.84	0.85	-4.79
		ENSEMBLE	26.17	±	0.19	1.03	1.38	0.97	0.91	0.93	1.84
	Mata Atlântica	Medido	23.65	±	0.17	-	-	-	-	-	-
		CPC	24.86	±	0.17	1.38	1.79	0.94	0.91	0.89	4.62
		ERA5-LAND	24.02	±	0.16	0.97	1.26	0.97	0.93	0.94	1.8
		GLDAS	22.97	±	0.16	1.32	1.63	0.95	0.88	0.91	-2.53
JRA55		24.87	±	0.16	1.58	1.95	0.93	0.88	0.87	5.01	
MERRA 2		23.85	±	0.17	1.26	1.61	0.96	0.88	0.92	1.04	
NCEP/DOE		22.93	±	0.15	1.5	1.86	0.94	0.84	0.88	-2.63	
ENSEMBLE		23.92	±	0.16	0.85	1.12	0.98	0.94	0.96	1.31	
Mensal	Amazônia	Medido	25.09	±	0.18	-	-	-	-	-	-
		CPC	26.75	±	0.23	1.73	1.95	0.59	0.59	0.32	6.1

		ERA5-LAND	25.48	±	0.21	0.66	0.92	0.83	0.73	0.7	1.38
		GLDAS	24.91	±	0.29	0.81	1.07	0.8	0.68	0.65	-0.69
		JRA55	25.86	±	0.28	1.08	1.45	0.61	0.38	0.38	1.75
		MERRA 2	25.95	±	0.33	1.14	1.49	0.67	0.56	0.46	2.79
		NCEP/DOE	24.62	±	0.24	0.93	1.15	0.72	0.62	0.52	-2.26
		ENSEMBLE	25.52	±	0.22	0.69	0.95	0.8	0.72	0.66	1.58
		Medido	23.69	±	0.28	-	-	-	-	-	-
		CPC	25.33	±	0.29	1.71	2.07	0.75	0.79	0.57	6.46
		ERA5-LAND	24.06	±	0.27	0.54	0.7	0.96	0.95	0.93	1.44
	Cerrado	GLDAS	23.17	±	0.34	0.88	1.1	0.92	0.86	0.85	-1.58
		JRA55	25.25	±	0.26	1.51	1.79	0.78	0.81	0.62	5.59
		MERRA 2	24.28	±	0.34	1	1.31	0.89	0.84	0.8	2.67
		NCEP/DOE	23.61	±	0.29	1.02	1.25	0.85	0.75	0.74	-1.07
		ENSEMBLE	24.2	±	0.28	0.73	0.95	0.93	0.92	0.87	2.35
		Medido	25.67	±	0.49	-	-	-	-	-	-
		CPC	26.81	±	0.41	1.51	2.07	0.75	0.65	0.56	4.37
		ERA5-LAND	26.25	±	0.48	0.69	0.89	0.94	0.9	0.88	1.95
	Pantanal	GLDAS	25.65	±	0.56	1.06	1.26	0.88	0.75	0.79	0.15
		JRA55	26.65	±	0.44	1.14	1.41	0.84	0.78	0.72	3.31
		MERRA 2	27.22	±	0.56	1.64	1.94	0.8	0.84	0.65	5.74
		NCEP/DOE	24.59	±	0.48	1.29	1.46	0.85	0.86	0.72	-4.71
		ENSEMBLE	26.12	±	0.46	0.66	0.89	0.94	0.9	0.88	1.92
		Medido	23.89	±	0.46	-	-	-	-	-	-
		CPC	25.17	±	0.49	1.17	1.38	0.89	0.93	0.8	4.63
		ERA5-LAND	24.2	±	0.41	0.57	0.73	0.97	0.95	0.94	1.74
	Mata Atlântica	GLDAS	23.22	±	0.45	0.86	1.03	0.94	0.9	0.89	-2.59
		JRA55	25.05	±	0.41	1.28	1.43	0.88	0.91	0.78	4.91
		MERRA 2	24.08	±	0.5	0.67	0.85	0.96	0.94	0.93	1.12
		NCEP/DOE	23.12	±	0.41	0.96	1.19	0.91	0.85	0.83	-2.58
		ENSEMBLE	24.1	±	0.43	0.48	0.62	0.98	0.96	0.95	1.3
		Medido	25.08	±	0.29	-	-	-	-	-	-
		CPC	26.69	±	0.48	1.66	1.85	0.48	0.4	0.18	6.1
		ERA5-LAND	25.43	±	0.39	0.56	0.73	0.81	0.66	0.66	1.38
	Amazônia	GLDAS	24.85	±	0.53	0.64	0.83	0.75	0.57	0.58	-0.7
		JRA55	25.79	±	0.56	0.95	1.25	0.44	0.09	0.13	1.72
		MERRA 2	25.86	±	0.66	0.98	1.27	0.55	0.4	0.29	2.77
		NCEP/DOE	24.58	±	0.29	0.83	1.02	0.52	0.51	0.27	-2.25
		ENSEMBLE	25.53	±	0.41	0.61	0.81	0.69	0.58	0.5	1.57
Anual		Medido	23.69	±	0.6	-	-	-	-	-	-
		CPC	25.33	±	0.67	1.69	1.99	0.69	0.76	0.48	6.47
		ERA5-LAND	24.06	±	0.55	0.48	0.59	0.96	0.95	0.93	1.45
	Cerrado	GLDAS	23.17	±	0.72	0.77	0.96	0.91	0.85	0.83	-1.6

	JRA55	25.24	±	0.52	1.47	1.7	0.71	0.8	0.52	5.61
	MERRA 2	24.28	±	0.64	0.9	1.2	0.86	0.82	0.75	2.66
	NCEP/DOE	23.61	±	0.36	0.95	1.15	0.77	0.7	0.61	-1.02
	ENSEMBLE	24.29	±	0.55	0.68	0.88	0.91	0.91	0.83	2.36
Pantanal	Medido	25.71	±	0.54	-	-	-	-	-	-
	CPC	26.86	±	0.58	1.37	1.82	0.63	0.67	0.39	4.31
	ERA5-LAND	26.29	±	0.67	0.63	0.79	0.84	0.73	0.72	2
	GLDAS	25.68	±	0.96	0.94	1.1	0.7	0.38	0.48	0.15
	JRA55	26.67	±	0.69	1.08	1.25	0.67	0.51	0.43	3.29
	MERRA 2	27.25	±	0.86	1.57	1.82	0.63	0.69	0.4	5.7
	NCEP/DOE	24.61	±	0.73	1.18	1.32	0.66	0.71	0.44	-4.73
	ENSEMBLE	26.23	±	0.59	0.57	0.77	0.85	0.76	0.73	1.9
Mata Atlântica	Medido	23.91	±	0.84	-	-	-	-	-	-
	CPC	25.14	±	1.05	1.14	1.26	0.8	0.91	0.66	4.58
	ERA5-LAND	24.21	±	0.65	0.48	0.62	0.95	0.94	0.9	1.69
	GLDAS	23.2	±	0.89	0.75	0.89	0.89	0.87	0.8	-2.64
	JRA55	25.09	±	0.81	1.24	1.33	0.77	0.91	0.61	4.91
	MERRA 2	24.09	±	0.84	0.51	0.65	0.95	0.93	0.9	1.1
	NCEP/DOE	23.13	±	0.71	0.89	1.07	0.79	0.67	0.64	-2.61
	ENSEMBLE	24.15	±	0.78	0.39	0.51	0.96	0.95	0.92	1.26

TABELA 13 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da temperatura do ar mínima ($T_{ar_{mín}}$) nas escalas diária, mensal e anual pelos produtos CPC, ERA5-LAND, GLDAS, JRA55, MERRA-2, NCEP/DOE e ENSEMBLE para a região Centro-Oeste do Brasil.

Escala	Produtos	Média \pm IC (°C)	MAE	RMSE	d	r	ρ_c	Pbias
Diária	Medido	18.37 \pm 0.11	-	-	-	-	-	-
	CPC	19.33 \pm 0.11	1.64	2.39	0.88	0.8	0.77	4.45
	ERA5-LAND	19.49 \pm 0.09	1.54	2.08	0.9	0.85	0.81	5.83
	GLDAS	18.53 \pm 0.10	1.46	1.96	0.91	0.81	0.83	1.37
	JRA55	20.80 \pm 0.08	2.66	3.53	0.73	0.62	0.53	11.29
	MERRA-2	18.67 \pm 0.11	1.44	1.93	0.92	0.83	0.85	2.4
	NCEP/DOE	20.15 \pm 0.11	2.17	2.82	0.83	0.72	0.69	8.05
	ENSEMBLE	19.49 \pm 0.09	1.48	2.01	0.9	0.87	0.82	5.68
Mensal	Medido	18.34 \pm 0.35	-	-	-	-	-	-
	CPC	19.28 \pm 0.36	1.21	1.66	0.86	0.81	0.74	4.37
	ERA5-LAND	19.44 \pm 0.31	1.24	1.54	0.88	0.9	0.78	5.72
	GLDAS	18.49 \pm 0.33	0.9	1.19	0.92	0.86	0.84	1.23
	JRA55	20.76 \pm 0.25	2.39	2.78	0.65	0.75	0.43	10.93
	MERRA-2	18.62 \pm 0.38	0.92	1.25	0.92	0.87	0.86	2.39
	NCEP/DOE	20.11 \pm 0.37	1.76	2.19	0.75	0.75	0.57	7.81
	ENSEMBLE	19.45 \pm 0.32	1.2	1.51	0.87	0.9	0.77	5.52
Anual	Medido	18.34 \pm 0.50	-	-	-	-	-	-
	CPC	19.28 \pm 0.36	1.11	1.48	0.81	0.75	0.66	4.36

ERA5-LAND	19.44	±	0.56	1.21	1.39	0.84	0.9	0.72	5.71
GLDAS	18.47	±	0.65	0.74	0.94	0.91	0.85	0.83	1.19
JRA55	20.76	±	0.56	2.36	2.56	0.6	0.81	0.36	10.9
MERRA-2	18.63	±	0.66	0.83	1.07	0.91	0.85	0.82	2.36
NCEP/DOE	20.13	±	0.76	1.71	2.07	0.64	0.66	0.41	7.77
ENSEMBLE	19.44	±	0.60	1.16	1.37	0.82	0.89	0.69	5.5

TABELA 14 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da temperatura do ar mínima ($T_{ar\ min}$) para os biomas Amazônia, Cerrado, Pantanal e Mata Atlântica dos produtos CPC, ERA-5, GLDAS, JRA55, MERRA-2, NCEP/DOE e ENSEMBLE para a região Centro-Oeste do Brasil.

Escala	Bioma	Produtos	Média \pm IC ($^{\circ}$ C)	MAE	RMSE	d	r	ρ_c	Pbias
Diária	Amazônia	Medido	20.41 \pm 0.11	-	-	-	-	-	-
		CPC	21.04 \pm 0.11	1.54	2.41	0.79	0.65	0.64	3.13
		ERA5-LAND	21.62 \pm 0.07	1.58	2.21	0.76	0.64	0.59	5.79
		GLDAS	20.48 \pm 0.09	1.35	1.82	0.85	0.64	0.73	-0.26
		JRA55	22.72 \pm 0.08	2.47	3.44	0.52	0.18	0.24	9.61
		MERRA-2	21.44 \pm 0.09	1.49	2.07	0.82	0.63	0.67	4.73
		NCEP/DOE	21.67 \pm 0.1	1.85	2.53	0.75	0.52	0.56	6.41
		ENSEMBLE	21.49 \pm 0.08	1.42	1.98	0.81	0.68	0.67	5
		Cerrado	Medido	18.72 \pm 0.11	-	-	-	-	-
	CPC		19.65 \pm 0.11	1.66	2.39	0.87	0.8	0.76	4.87
	ERA5-LAND		19.79 \pm 0.09	1.5	2.03	0.9	0.86	0.81	5.61
	GLDAS		18.97 \pm 0.1	1.48	1.99	0.9	0.8	0.81	1.91
	JRA55		21.18 \pm 0.08	2.72	3.59	0.7	0.61	0.49	11.75
	MERRA-2		19 \pm 0.12	1.43	1.91	0.92	0.83	0.84	2.18
	NCEP/DOE		20.3 \pm 0.11	2.29	2.92	0.8	0.72	0.65	8.9
	ENSEMBLE		19.82 \pm 0.1	1.51	2.05	0.89	0.87	0.8	6
	Pantanal		Medido	20.88 \pm 0.22	-	-	-	-	-
		CPC	21.46 \pm 0.17	2.1	3.13	0.85	0.63	0.72	2.69
		ERA5-LAND	22.22 \pm 0.2	1.85	2.41	0.91	0.83	0.83	6.01
		GLDAS	20.95 \pm 0.2	1.84	2.39	0.91	0.75	0.83	0.37
		JRA55	23.14 \pm 0.18	2.56	3.44	0.82	0.68	0.67	9.57
		MERRA-2	21.46 \pm 0.22	1.72	2.23	0.93	0.82	0.87	2.75
		NCEP/DOE	21.39 \pm 0.22	1.85	2.51	0.91	0.77	0.83	2.48
		ENSEMBLE	21.77 \pm 0.19	1.53	2.12	0.93	0.84	0.86	4.08
		Mata Atlântica	Medido	18.57 \pm 0.18	-	-	-	-	-
	CPC		19.55 \pm 0.18	1.52	2.15	0.93	0.86	0.87	4.77
	ERA5-LAND		19.82 \pm 0.16	1.63	2.1	0.93	0.9	0.87	7.02
	GLDAS		18.74 \pm 0.16	1.4	1.85	0.94	0.86	0.89	1.27
JRA55	20.95 \pm 0.15		2.66	3.3	0.83	0.79	0.7	11.97	
MERRA-2	18.37 \pm 0.19		1.35	1.74	0.96	0.89	0.92	-0.46	

		NCEP/DOE	19.7	± 0.16	2.09	2.73	0.89	0.8	0.79	7.75
		ENSEMBLE	19.52	± 0.16	1.37	1.83	0.95	0.92	0.9	5.57
		Medido	20.42	± 0.32	-	-	-	-	-	-
		CPC	21.05	± 0.32	1.13	1.51	0.76	0.61	0.59	3.04
		ERA5-LAND	21.62	± 0.2	1.27	1.62	0.68	0.67	0.48	5.55
	Amazônia	GLDAS	20.48	± 0.24	0.8	1.05	0.84	0.7	0.71	-0.47
		JRA55	22.72	± 0.18	2.15	2.64	0.38	0.17	0.1	9.23
		MERRA-2	21.43	± 0.28	1.11	1.49	0.74	0.64	0.55	4.54
		NCEP/DOE	21.67	± 0.3	1.45	1.85	0.65	0.57	0.42	6.26
		ENSEMBLE	21.34	± 0.23	1.13	1.46	0.71	0.7	0.53	4.79
		Medido	18.68	± 0.37	-	-	-	-	-	-
		CPC	19.6	± 0.37	1.25	1.72	0.84	0.8	0.71	4.81
		ERA5-LAND	19.74	± 0.32	1.19	1.48	0.88	0.91	0.78	5.56
	Cerrado	GLDAS	18.91	± 0.34	0.93	1.24	0.91	0.86	0.82	1.81
		JRA55	21.12	± 0.25	2.45	2.85	0.62	0.75	0.4	11.41
		MERRA-2	18.94	± 0.39	0.89	1.22	0.92	0.87	0.85	2.19
		NCEP/DOE	20.27	± 0.37	1.91	2.33	0.71	0.74	0.52	8.65
		ENSEMBLE	19.61	± 0.33	1.25	1.56	0.86	0.9	0.74	5.86
Mensal		Medido	20.88	± 0.56	-	-	-	-	-	-
		CPC	21.49	± 0.47	1.36	2.01	0.81	0.64	0.66	2.79
		ERA5-LAND	22.26	± 0.51	1.49	1.81	0.83	0.82	0.7	5.89
	Pantanal	GLDAS	21	± 0.49	1.25	1.51	0.85	0.71	0.74	0.28
		JRA55	23.16	± 0.4	2.18	2.62	0.65	0.72	0.44	9.27
		MERRA-2	21.52	± 0.59	1.1	1.43	0.9	0.83	0.82	2.91
		NCEP/DOE	21.44	± 0.56	1.14	1.5	0.87	0.78	0.77	2.48
		ENSEMBLE	21.68	± 0.48	1.08	1.46	0.88	0.83	0.78	4.02
		Medio	18.57	± 0.18	-	-	-	-	-	-
		CPC	19.88	± 0.59	1.05	1.44	0.91	0.88	0.82	4.64
		ERA5-LAND	20.04	± 0.47	1.37	1.6	0.88	0.94	0.79	6.83
	Mata Atlântica	GLDAS	19	± 0.47	0.76	1	0.95	0.91	0.9	1.1
		JRA55	21.07	± 0.37	2.44	2.68	0.69	0.87	0.5	11.61
		MERRA-2	18.63	± 0.57	0.71	0.88	0.97	0.94	0.94	-0.49
		NCEP/DOE	19.79	± 0.44	1.62	2.05	0.8	0.8	0.66	7.51
		ENSEMBLE	19.61	± 0.47	1.08	1.32	0.91	0.94	0.84	5.37
		Medido	20.52	± 0.47	-	-	-	-	-	-
		CPC	21.05	± 0.32	1	1.3	0.63	0.48	0.37	3.03
		ERA5-LAND	21.66	± 0.34	1.23	1.4	0.59	0.68	0.35	5.54
	Amazônia	GLDAS	20.54	± 0.34	0.59	0.78	0.75	0.62	0.58	-0.5
		JRA55	22.72	± 0.31	2.1	2.34	0.31	0.07	0.05	9.19
		MERRA-2	21.46	± 0.34	1.04	1.3	0.57	0.57	0.32	4.51
		NCEP/DOE	21.72	± 0.64	1.39	1.69	0.48	0.48	0.2	6.24
		ENSEMBLE	21.52	± 0.29	1.08	1.28	0.55	0.66	0.32	4.76
Anual		Medido	20.52	± 0.47	-	-	-	-	-	-
		CPC	21.05	± 0.32	1	1.3	0.63	0.48	0.37	3.03
		ERA5-LAND	21.66	± 0.34	1.23	1.4	0.59	0.68	0.35	5.54
	Amazônia	GLDAS	20.54	± 0.34	0.59	0.78	0.75	0.62	0.58	-0.5
		JRA55	22.72	± 0.31	2.1	2.34	0.31	0.07	0.05	9.19
		MERRA-2	21.46	± 0.34	1.04	1.3	0.57	0.57	0.32	4.51
		NCEP/DOE	21.72	± 0.64	1.39	1.69	0.48	0.48	0.2	6.24
		ENSEMBLE	21.52	± 0.29	1.08	1.28	0.55	0.66	0.32	4.76

Cerrado	Medido	18.67	± 0.59	-	-	-	-	-	-
	CPC	19.59	± 0.68	1.17	1.55	0.78	0.72	0.61	4.8
	ERA5-LAND	19.73	± 0.63	1.16	1.34	0.84	0.89	0.72	5.54
	GLDAS	18.9	± 0.74	0.78	0.98	0.9	0.83	0.81	1.77
	JRA55	21.12	± 0.62	2.43	2.63	0.58	0.8	0.34	11.36
	MERRA-2	18.94	± 0.74	0.8	1.05	0.9	0.83	0.81	2.17
	NCEP/DOE	20.25	± 0.77	1.86	2.22	0.58	0.59	0.34	8.59
	ENSEMBLE	19.76	± 0.66	1.21	1.42	0.8	0.87	0.65	5.83
Pantanal	Medido	20.9	± 0.53	-	-	-	-	-	-
	CPC	21.51	± 0.72	1.18	1.71	0.7	0.56	0.5	2.77
	ERA5-LAND	22.29	± 0.63	1.44	1.71	0.61	0.54	0.38	5.99
	GLDAS	21	± 0.7	1.12	1.31	0.65	0.37	0.4	0.3
	JRA55	23.19	± 0.53	2.17	2.43	0.43	0.53	0.19	9.33
	MERRA-2	21.54	± 0.78	0.95	1.27	0.8	0.65	0.64	2.98
	NCEP/DOE	21.46	± 1.02	1.02	1.28	0.75	0.57	0.55	2.52
	ENSEMBLE	21.82	± 0.57	1	1.32	0.73	0.62	0.54	4.07
Mata Atlântica	Medido	18.88	± 1.05	-	-	-	-	-	-
	CPC	19.87	± 1.3	0.97	1.28	0.82	0.78	0.68	4.63
	ERA5-LAND	20.04	± 0.75	1.35	1.52	0.76	0.85	0.58	6.8
	GLDAS	19.01	± 0.96	0.58	0.76	0.92	0.82	0.84	1.03
	JRA55	21.12	± 0.71	2.43	2.56	0.48	0.8	0.27	11.62
	MERRA-2	18.66	± 0.91	0.63	0.7	0.94	0.86	0.89	-0.52
	NCEP/DOE	19.84	± 0.79	1.55	1.95	0.62	0.52	0.37	7.52
	ENSEMBLE	19.76	± 0.83	1.05	1.23	0.81	0.87	0.67	5.35

Umidade relativa do ar (UR)

TABELA 15 Médias \pm Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da umidade relativa do ar (UR) nas escalas diária, mensal e anual pelos produtos ERA5-LAND, GLDAS, JRA55 e NCEP/DOE para a região Centro-Oeste do Brasil.

Escala	Produto	Média \pm IC ($^{\circ}$ C)	MAE	RMSE	d	r	ρ_c	Pbias
Diário	Medido	68.94 \pm 0.05	-	-	-	-	-	-
	GLDAS	74.03 \pm 0.06	10.94	13.33	0.85	0.76	0.74	7.4
	ERA5-LAND	66.88 \pm 0.05	5.73	7.58	0.94	0.9	0.89	-3
	JRA 55	60.98 \pm 0.06	10.08	12.74	0.86	0.83	0.75	-11.5
	NCEP/DOE	76.92 \pm 0.05	10.79	12.91	0.84	0.8	0.72	11.6
Mensal	Medido	68.9 \pm 0.2	-	-	-	-	-	-
	GLDAS	73.99 \pm 0.3	9.84	11.88	0.85	0.77	0.73	7.4
	ERA5-LAND	66.96 \pm 0.23	4.34	5.98	0.95	0.92	0.9	-2.8
	JRA 55	61.07 \pm 0.25	8.7	10.51	0.86	0.87	0.75	-11.4

	NCEP/DOE	76.97 ± 0.23	9.14	10.55	0.85	0.87	0.73	11.7
	Medido	69.32 ± 0.33	-	-	-	-	-	-
Anual	GLDAS	74.34 ± 0.44	7.84	9.74	0.57	0.31	0.29	7.2
	ERA5-LAND	67.37 ± 0.34	3.33	4.58	0.87	0.81	0.75	-2.8
	JRA 55	61.58 ± 0.43	8.08	9.3	0.68	0.79	0.47	-11.2
	NCEP/DOE	77.07 ± 0.31	8.1	9.24	0.62	0.66	0.36	11.2

TABELA 16 Médias ± Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias da umidade relativa do ar (UR) para os biomas Amazônia, Cerrado, Pantanal e Mata Atlântica dos produtos ERA5-LAND, GLDAS, JRA55 e NCEP/DOE para a região Centro-Oeste do Brasil.

Bioma	Produto	Média ± IC (°C)	MAE	RMSE	d	r	ρ_c	Pbias
Amazônia	Medido	74.53 ± 0.45	-	-	-	-	-	-
	GLDAS	73.82 ± 0.71	8.06	10.08	0.88	0.88	0.79	-1
	ERA5-LAND	73.41 ± 0.58	5.4	7.44	0.92	0.86	0.85	-1.5
	JRA 55	71.21 ± 0.59	5.52	8.01	0.91	0.87	0.83	-4.4
	NCEP/DOE	80.45 ± 0.56	8.24	9.53	0.87	0.86	0.76	8
Mata Atlântica	Medido	67.39 ± 0.26	-	-	-	-	-	-
	GLDAS	73.92 ± 0.38	10.32	12.34	0.85	0.8	0.73	9.7
	ERA5-LAND	65.13 ± 0.28	4.16	5.7	0.96	0.92	0.91	-3.3
	JRA 55	58.12 ± 0.3	9.75	11.32	0.85	0.88	0.73	-13.8
	NCEP/DOE	76.17 ± 0.28	9.59	10.97	0.85	0.88	0.73	13
Cerrado	Medido	68.92 ± 0.44	-	-	-	-	-	-
	GLDAS	77.29 ± 0.64	10.05	12.09	0.75	0.72	0.58	12.2
	ERA5-LAND	67.51 ± 0.47	3.74	5.12	0.93	0.86	0.86	-2
	JRA 55	61.06 ± 0.44	8.3	9.68	0.78	0.8	0.61	-11.4
	NCEP/DOE	76.75 ± 0.5	8.42	9.94	0.78	0.8	0.63	11.4
Pantanal	Medido	68.78 ± 0.76	-	-	-	-	-	-
	GLDAS	65.93 ± 1.27	9.26	11.01	0.79	0.72	0.64	-4.1
	ERA5-LAND	66.51 ± 0.81	4.35	5.66	0.91	0.85	0.83	-3.3
	JRA 55	64.56 ± 0.98	6.62	8.82	0.83	0.75	0.69	-6.1
	NCEP/DOE	75.26 ± 0.96	7.97	9.55	0.8	0.79	0.66	9.4

Déficit de pressão de vapor (DPV)

TABELA 17 Médias ± Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias do déficit de pressão de vapor (DPV) nas escalas diária, mensal e anual pelos produtos ERA5-LAND, GLDAS, JRA55 e NCEP/DOE para a região Centro-Oeste do Brasil.

Escala	Produto	Média ± IC (°C)	MAE	RMSE	d	r	ρ_c	Pbias
Diário	MEDIDO	0.96 ± 0.0	-	-	-	-	-	-

	ERA5-LAND	1.05 ± 0.0	0.21	0.3	0.93	0.88	0.87	9.5
	GLDAS	0.83 ± 0.0	0.38	0.47	0.86	0.75	0.74	-14
	JRA55	1.32 ± 0.0	0.43	0.58	0.82	0.8	0.68	37.7
	NCEP/DOE	0.71 ± 0.0	0.37	0.45	0.84	0.77	0.71	-26.4
	MEDIDO	0.94 ± 0.01	-	-	-	-	-	-
Mensal	ERA5-LAND	1.04 ± 0.01	0.16	0.23	0.93	0.9	0.87	9.8
	GLDAS	0.81 ± 0.01	0.33	0.4	0.85	0.77	0.73	-13.7
	JRA55	1.29 ± 0.01	0.37	0.47	0.81	0.82	0.66	36.9
	NCEP/DOE	0.69 ± 0.01	0.3	0.35	0.85	0.83	0.73	-26.5
	MEDIDO	0.92 ± 0.01	-	-	-	-	-	-
Anual	ERA5-LAND	1.01 ± 0.01	0.13	0.17	0.84	0.77	0.71	9.4
	GLDAS	0.78 ± 0.02	0.26	0.32	0.62	0.46	0.38	-15.7
	JRA55	1.25 ± 0.01	0.34	0.38	0.6	0.69	0.36	35.4
	NCEP/DOE	0.68 ± 0.01	0.26	0.3	0.61	0.62	0.34	-26.6
	MEDIDO	0.92 ± 0.01	-	-	-	-	-	-

TABELA 18 Médias ± Intervalo de Confiança (IC), erro médio absoluto (MAE), erro médio da raiz quadrada (RMSE), índice de concordância de Wilmott (d), correlação de Spearman (r), coeficiente de concordância de Lin (ρ_c) e Pbias do déficit de pressão de vapor (DPV) para os biomas Amazônia, Cerrado, Pantanal e Mata Atlântica dos produtos ERA5-LAND, GLDAS, JRA55 e NCEP/DOE para a região Centro-Oeste do Brasil.

Biomias	Produto	Média ± IC (°C)	MAE	RMSE	d	r	ρ_c	Pbias
Amazônia	MEDIDO	0.82 ± 0.02	-	-	-	-	-	-
	ERA5	0.9 ± 0.02	0.22	0.32	0.88	0.85	0.79	10
	GLDAS	0.88 ± 0.03	0.3	0.4	0.85	0.86	0.74	6.9
	JRA55	1.0 ± 0.03	0.25	0.41	0.84	0.84	0.73	21.4
	NCEP/DOE	0.63 ± 0.02	0.29	0.34	0.86	0.84	0.74	-23.4
Mata Atlântica	MEDIDO	0.9 ± 0.02	-	-	-	-	-	-
	ERA5	0.98 ± 0.02	0.14	0.19	0.93	0.85	0.86	8.2
	GLDAS	0.66 ± 0.02	0.32	0.38	0.78	0.69	0.61	-27.3
	JRA55	1.22 ± 0.02	0.33	0.38	0.76	0.78	0.58	35.4
	NCEP/DOE	0.65 ± 0.02	0.27	0.33	0.78	0.71	0.61	-27.4
Cerrado	MEDIDO	0.98 ± 0.01	-	-	-	-	-	-
	ERA5	1.07 ± 0.01	0.15	0.21	0.95	0.91	0.9	9.9
	GLDAS	0.8 ± 0.01	0.34	0.4	0.86	0.8	0.75	-17.8
	JRA55	1.38 ± 0.01	0.42	0.5	0.8	0.84	0.65	41.7
	NCEP/DOE	0.71 ± 0.01	0.3	0.36	0.85	0.84	0.73	-27.1
Pantanal	MEDIDO	1.04 ± 0.03	-	-	-	-	-	-
	ERA5	1.16 ± 0.03	0.19	0.25	0.89	0.82	0.79	11.9
	GLDAS	1.18 ± 0.05	0.39	0.48	0.74	0.67	0.57	13.5
	JRA55	1.26 ± 0.04	0.29	0.41	0.76	0.68	0.59	21
	NCEP/DOE	0.78 ± 0.03	0.31	0.38	0.77	0.73	0.6	-24.5

4. CONSIDERAÇÕES FINAIS DA TESE

O presente estudo representa uma avaliação abrangente dos dados de velocidade do vento, precipitação, temperatura do ar, umidade relativa do ar e déficit de pressão de vapor, estimados por diversos produtos de sensoriamento remoto e reanálise em comparação com dados medidos em estações meteorológicas automáticas de superfície localizadas no estado de Mato Grosso, Brasil. Os resultados obtidos fornecem uma base sólida para a validação desses dados climáticos, contribuindo significativamente para pesquisas que dependem dessas informações cruciais.

Os resultados indicam uma concordância notável entre os dados simulados e observados, com coeficientes de determinação elevados para as variáveis analisadas. Os resultados deste estudo têm implicações significativas para pesquisas que dependem de dados climáticos precisos, particularmente aquelas relacionadas ao estado de Mato Grosso. A validação bem-sucedida destes dados abre novas perspectivas para investigações futuras, contribuindo para uma compreensão mais precisa e confiável das condições climáticas locais.

Para avançar na compreensão climática da região, sugere-se a expansão da validação para outras áreas do Brasil, incorporando uma variedade mais extensa de variáveis climáticas. Além disso, a inclusão de um maior número de estações meteorológicas e a consideração de novos produtos de satélite e reanálise são fundamentais para a robustez e generalização dos resultados. Recomenda-se também a extensão da série temporal, permitindo uma análise mais abrangente das tendências climáticas ao longo do tempo.

5. REFERÊNCIAS DA INTRODUÇÃO GERAL E FUNDAMENTAÇÃO TEÓRICA

ALEXANDER, L. V. ET AL. On the use of indices to study extreme precipitation on sub-daily and daily timescales. **Environmental Research Letters**, v. 14, n. 12, p. 125008, dez. 2019.

ALEXANDER, L. V. ET AL. Intercomparison of annual precipitation indices and extremes over global land areas from in situ, space-based and reanalysis products. **Environmental Research Letters**, v. 15, n. 5, p. 055002, abr. 2020.

AGUTU, N. O., AWANGE, J. L., ZERIHUN, A., NDEHEDEHE, C. E., KUHN, M., & FUKUDA, Y. (2017). Assessing multi-satellite remote sensing, reanalysis, and land surface models' products in characterizing agricultural drought in East Africa. **Remote Sensing of Environment**, 194, 287–302. <https://doi.org/10.1016/j.rse.2017.03.041>

ALMAGRO, A., OLIVEIRA, P. T. S., & BROCCA, L. (2021). Assessment of bottom-up satellite rainfall products on estimating river discharge and hydrologic signatures in Brazilian catchments. **Journal of Hydrology**, 603, 126897. <https://doi.org/10.1016/j.jhydrol.2021.126897>

ALVES, J. M. B., ET AL. (2020). Climate change impacts on drought risk in Brazilian Cerrado. **Agricultural and Forest Meteorology**, 287, 107936.

ARAÚJO PALHARINI, R. S. et al. Assessment of extreme rainfall estimates from satellite-based: Regional analysis. **Remote Sensing Applications: Society and Environment**, v. 23, p. 100603, 1 ago. 2021.

BASSETTO, M., ET AL. (2019). Disponibilidade de dados climáticos na região Centro-Oeste do Brasil. **Revista Brasileira de Climatologia**, 24, 363-379.

BENGHANEM, M. Measurement of meteorological data based on wireless data acquisition system monitoring. **Applied Energy**, v. 86, n. 12, p. 2651–2660, 1 dez. 2009.

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(11), 2147–2161. <https://doi.org/10.1175/JHM-D-19-0073.1>

BLAINSKI, É.; GARBOSSA, L. H. P.; ANTUNES, E. N. Estações hidrometeorológicas automáticas: recomendações técnicas para instalação. 2012.

DUAN, Z. ET AL. Evaluation of eight high spatial resolution gridded precipitation products in Adige Basin (Italy) at multiple temporal and spatial scales. **Science of The Total Environment**, v. 573, p. 1536–1553, 15 dez. 2016.

ENENKEL, M. ET AL. Why predict climate hazards if we need to understand impacts? Putting humans back into the drought equation. **Climatic Change**, v. 162, n. 3, p. 1161–1176, 1 out. 2020.

GAO, F. ET AL. Comparison of two long-term and high-resolution satellite precipitation datasets in Xinjiang, China. **Atmospheric Research**, v. 212, p. 150–157, 1 nov. 2018.

GARCIA, R., RODRIGUEZ, M., & MARTINEZ, L.(2023). "Advancements in Climate Research: Integrating Remote Sensing and Reanalysis for Precise Analysis." **Journal of Atmospheric Sciences**, 78(2), 87-102.

GEHNE, M. ET AL. Comparison of Global Precipitation Estimates across a Range of Temporal and Spatial Scales. **Journal of Climate**, v. 29, n. 21, p. 7773–7795, 1 nov. 2016.

GELARO, R., MCCARTY, W., SUÁREZ, M. J., TODLING, R., MOLOD, A., TAKACS, L., RANGLES, C. A., DARMENOV, A., BOSILOVICH, M. G., REICHLER, R., WARGAN, K., COY, L., CULLATHER, R., DRAPER, C., AKELLA, S., BUCHARD, V., CONATY, A., SILVA, A. M. DA, GU, W., ... ZHAO, B. (2017). The Modern-Era Retrospective Analysis for Research and Applications, Version 2 (MERRA-2). **Journal of Climate**, 30(14), 5419–5454. <https://doi.org/10.1175/JCLI-D-16-0758.1>

GODINHO, A. L. B., et al. (2020). Análise de crescimento econômico e agropecuário no Brasil. **Boletim Goiano de Geografia**, 40(1), 105-123.

GOLUBKOV, G. V. ET AL. The Problems of Passive Remote Sensing of the Earth's Surface in the Range of 1.2–1.6 GHz. **Atmosphere**, v. 11, n. 6, p. 650, jun. 2020.

JIANG, J., ET AL. (2021). Global Climate Monitoring by Satellite Observation Systems. *Bulletin*.

OLIVEIRA, G. G. D., ET AL. (2022). Climate Information Needs for Decision Making in the Brazilian Center-West Region: Challenges and Prospects. **Atmosphere**, 13(1), 1-16.

JONES, J. E. ET AL. Building and Validating Multidimensional Datasets in Hydrology for Data and Mapping Web Service Compliance. **Water**, v. 15, n. 3, p. 411, jan. 2023.

KUMAR, S. ET AL. CHAPTER 5 - Remote sensing for agriculture and resource management. Em: Jhariya, M. K. et al. (Eds.). **Natural Resources Conservation and Advances for Sustainability**. [s.l.] Elsevier, 2022. p. 91–135.

LAN HUONG, T. T. ET AL. Disaster risk management system in Vietnam: progress and challenges. **Heliyon**, v. 8, n. 10, p. e10701, out. 2022.

LEVIZZANI, V.; CATTANI, E. Satellite Remote Sensing of Precipitation and the Terrestrial Water Cycle in a Changing Climate. **Remote Sensing**, v. 11, n. 19, p. 2301, jan. 2019.

LÓPEZ-BERMEJO, C. ET AL. Validation of the accuracy of the CHIRPS precipitation dataset at representing climate variability in a tropical mountainous region of South America. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 127, p. 103184, 1 out. 2022.

MERTIKAS, S. P. ET AL. Chapter 3 - Environmental applications of remote sensing. Em: Mohamed, A.-M. O.; Paleologos, E. K.; Howari, F. M. (Eds.). **Pollution Assessment for**

Sustainable Practices in Applied Sciences and Engineering. [s.l.] Butterworth-Heinemann, 2021. p. 107–163.

NAVARRO-RACINES, C. et al. High-resolution and bias-corrected CMIP5 projections for climate change impact assessments. **Scientific Data**, v. 7, n. 1, p. 7, 20 jan. 2020.

OLIVEIRA, F., SOUZA, P., & COSTA, L. (2022). "Spatial and Temporal Variability of Climate Parameters in the Central-West Region of Brazil: Insights from **Remote Sensing and Reanalysis**." *Climatic Change*, 145(1), 78-95.

PANDA, A.; SAHU, N. Trend analysis of seasonal rainfall and temperature pattern in Kalahandi, Bolangir and Koraput districts of Odisha, India. **Atmospheric Science Letters**, v. 20, n. 10, p. e932, 2019.

PEI, T. ET AL. GIScience and remote sensing in natural resource and environmental research: Status quo and future perspectives. **Geography and Sustainability**, v. 2, n. 3, p. 207–215, 1 set. 2021.

RAMON, J. ET AL. What global reanalysis best represents near-surface winds? **Quarterly Journal of the Royal Meteorological Society**, v. 145, n. 724, p. 3236–3251, 2019.

ROCHA, A. C. P., ET AL. (2018). Geomorphology of the Brazilian Midwest: Plateaus, hills, and plains. **Geomorphology**, 318, 126-135.

SELVAN, C.; BALASUNDARAM, S. R. Data Analysis in Context-Based Statistical Modeling in Predictive Analytics. Em: **Handbook of Research on Engineering, Business, and Healthcare Applications of Data Science and Analytics**. [s.l.] IGI Global, 2021. p. 96–114.

SILVA, J., SANTOS, M., & PEREIRA, A. (2021). "Validating and Adapting Remote Sensing and Reanalysis Products for the Central-West Region of Brazil." **International Journal of Climatology**, 41(5), 234-256.

SMITH, A., JOHNSON, B., & THOMPSON, C. (2022). "Understanding Climate Patterns: A Comprehensive Analysis Using Remote Sensing, Reanalysis, and Observations." **Journal of Climate**, 45(3), 123-145.

SKOFRONICK-JACKSON, G., PETERSEN, W. A., BERG, W., KIDD, C., STOCKER, E. F., KIRSCHBAUM, D. B., KAKAR, R., BRAUN, S. A., HUFFMAN, G. J., IGUCHI, T., KIRSTETTER, P. E., KUMMEROW, C., MENEGHINI, R., OKI, R., OLSON, W. S., TAKAYABU, Y. N., FURUKAWA, K., & WILHEIT, T. (2017). The Global Precipitation Measurement (GPM) Mission for Science and Society. **Bulletin of the American Meteorological Society**, 98(8), 1679–1695. <https://doi.org/10.1175/BAMS-D-15-00306.1>

SOUZA, P. F. D., ET AL. (2021). The Brazilian Cerrado: A global hotspot of biodiversity. **Journal for Nature Conservation**, 61, 125978.

THORNE, P. W. ET AL. Toward an Integrated Set of Surface Meteorological Observations for Climate Science and Applications. **Bulletin of the American Meteorological Society**, v. 98, n. 12, p. 2689–2702, 1 dez. 2017.

UPPALA, S. M. ET AL. The ERA-40 re-analysis. **Quarterly Journal of the Royal Meteorological Society**, v. 131, n. 612, p. 2961–3012, 2005.

VENTURA, T. ET AL. Análise da aplicabilidade de métodos estatísticos para preenchimento de falhas em dados meteorológicos. **Revista Brasileira de Climatologia**, v. 19, p. 168, 1 dez. 2016.

6. ANEXO DA TESE

TABELA 19 Descrição das estações meteorológicas automáticas de superfície e disponibilidade dos dados utilizados para validar as estimativas dos produtos de temperatura do ar média, máxima e mínima, umidade relativa do ar e déficit de pressão de vapor estimados pelo CPC, CHIRPS, ERA-5, GLDAS, GPCP, GPM, JRA-55, MERRA-2, NCEP/DOE e TRMM para a região Centro-Oeste do Brasil.

ID 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	Caiapônia – 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 Brilhante – 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