



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

**ISRAEL OLIVEIRA IVO**

**ESTIMATIVA DO CONTEÚDO DE ÁGUA NO SOLO,  
EVAPOTRANSPIRAÇÃO E PRODUTIVIDADE PRIMÁRIA BRUTA POR  
REANÁLISE E SENSORIAMENTO REMOTO NOS BIOMAS DE MATO  
GROSSO**

**CUIABÁ - MT  
2024**

**ISRAEL OLIVEIRA IVO**

**ESTIMATIVA DO CONTEÚDO DE ÁGUA NO SOLO,  
EVAPOTRANSPIRAÇÃO E PRODUTIVIDADE PRIMÁRIA BRUTA POR  
REANÁLISE E SENSORIAMENTO REMOTO NOS BIOMAS DE MATO  
GROSSO**

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 Doutor em Física Ambiental.

Orientador: Prof. Dr. Marcelo Sacardi Biudes

**CUIABÁ-MT  
2024**

## Dados Internacionais de Catalogação na Fonte.

196e Ivo, Israel Oliveira.

Estimativa do conteúdo de água no solo, evapotranspiração e produtividade primária bruta por reanálise e sensoriamento remoto nos biomas de Mato Grosso [recurso eletrônico] / Israel Oliveira Ivo. -- Dados eletrônicos (1 arquivo : 101 f., pdf). -- 2024.

Orientador: Marcelo Sacardi Biudes.

Tese (doutorado) - Universidade Federal de Mato Grosso, Instituto de Física, Programa de Pós-Graduação em Física Ambiental, Cuiabá, 2024.

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

Inclui bibliografia.

1. Cobertura do solo. 2. Balanço hídrico. 3. Ciclo do carbono. I. Biudes, Marcelo Sacardi, *orientador*. II. Título.

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: ESTIMATIVA DO CONTEÚDO DE ÁGUA NO SOLO, EVAPOTRANSPIRAÇÃO E PRODUTIVIDADE PRIMÁRIA BRUTA POR REANÁLISE E SENSORIAMENTO REMOTO NOS BIOMAS DE MATO GROSSO**

**AUTOR: DOUTORANDO ISRAEL OLIVEIRA IVO**

Tese defendida e aprovada em **01 de novembro de 2024**.

**COMPOSIÇÃO DA BANCA EXAMINADORA**

**1. Prof. Dr. MARCELO SACARDI BIUDES** (Presidente Banca / **ORIENTADOR**)

INSTITUIÇÃO: UNIVERSIDADE FEDERAL DE MATO GROSSO

**2. Profa. Dra. NADJA GOMES MACHADO** (Membro Interno)

INSTITUIÇÃO: INSTITUTO FEDERAL DE MATO GROSSO

**3. Prof. Dr. LEONE FRANCISCO AMORIM CURADO** (Membro Interno)

INSTITUIÇÃO: UNIVERSIDADE FEDERAL DE MATO GROSSO

**4. Prof. Dr. JONATHAN WILLIAN ZANGESKI NOVAIS** (Membro Externo)

INSTITUIÇÃO: INSTITUTO FEDERAL DE MATO GROSSO

**5. Prof. Dr. CARLOS ALEXANDRE SANTOS QUERINO** (Membro Externo)

INSTITUIÇÃO: UNIVERSIDADE FEDERAL DO AMAZONAS

**Cuiabá, 01/11/2024.**



Documento assinado eletronicamente por **MARCELO SACARDI BIUDES**, Docente da Universidade Federal de Mato Grosso, em 04/11/2024, às 15:17, 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 04/11/2024, às 15:07, 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 **Jonathan Willian Zangeski Novais, Usuário Externo**, em 04/11/2024, às 15:23, 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 04/11/2024, às 15:27, 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 05/11/2024, às 11:34, 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](http://sei.ufmt.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **7335473** e o código CRC **EBBEE2F8**.

Dedico este trabalho a Deus, por toda providência e graça derramada em minha vida, aos meus amigos e familiares, e à minha esposa Jamille, que sempre me apoia, me ama e é presença na minha vida.

## **AGRADECIMENTOS**

Agradeço a

Universidade Federal de Mato Grosso (UFMT) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de doutorado;

Minha esposa Jamille Silva de Oliveira, por me apoiar em todos os meus projetos e por ser uma amiga e parceira incondicional;

Meus Pais Juarez Ivo e Maria Aparecida de Oliveira Ivo, por toda educação, amor e exemplo com que me instruíram para fazer o bem;

Prof. Dr. Marcelo Sacardi Biudes, pela orientação e principalmente pelo incentivo, apoio, sinceridade, confiança e grande amizade, ingredientes que possibilitaram a realização deste;

Profa. Dra. Nadja Gomes Machado, por sua ajuda em conhecimentos e conselhos, sem os quais este trabalho não teria a mesma qualidade;

Meus parceiros do Grupo de Pesquisa Interação Biosfera-Atmosfera (GPIBA) do Programa de Pós-Graduação em Física Ambiental, sobretudo Lucas que contribuiu grandemente com a obtenção do banco de dados do segundo artigo desta tese;

Todos os docentes do Programa de Pós-Graduação em Física Ambiental da Universidade Federal de Mato Grosso, onde transmitiram seus conhecimentos;

“Vós sois o sal da terra. Se o sal perde o sabor, com que lhe será restituído o sabor?... Vós sois a luz do mundo... Assim, brilhe vossa luz diante dos homens, para que vejam as vossas boas obras e glorifiquem vosso Pai que está nos céus.”

*(Mt 5, 13-16)*

## RESUMO

Dados de satélite confiáveis e estimativas de variáveis microclimáticas em larga escala tem sido uma necessidade crescente em estudos microclimáticos em Mato Grosso. A região, que abriga três importantes biomas brasileiros, tem vivido um intenso processo de modificação de paisagem. Entender os efeitos da modificação dessas áreas de vegetação nativa sobre os fluxos de energia e massa, além de seus fatores, é suma importância para o desenvolvimento de políticas de gestão de recursos naturais. No presente estudo foram avaliadas estimativas do conteúdo de água no solo (SM), da evapotranspiração (ET) e da produtividade primária bruta (GPP) em áreas formação natural e antropizadas em Mato Grosso. As estimativas foram obtidas de produtos de reanálise, sensoriamento remoto e pelo Thermal-Optical Trapezoid Model (TOTRAM). Esses dados foram também agrupados em Multi-model ensembles (MME) gerando novas estimativas. Os resultados do estudo foram distribuídos em dois artigos, o primeiro avaliando as estimativas de SM e o segundo avaliando as estimativas da ET e GPP. A combinação dos produtos de SM, ET e GPP no MME gerou estimativas com maior correlação, concordância e menores erros, além de preservar a variabilidade espacial dos produtos. Os produtos SSEBop, GLEAM e PML e o MME tiveram os melhores desempenhos de validação, sobretudo no Pantanal. A pesquisa concluiu que as estimativas de MMEs permitem obter dados com maior confiabilidade e abrangência, viabilizando estudos regiões de difícil acesso ou locais mais remotos. Esses resultados também oferecem para a sociedade uma alternativa mais segura no desenvolvimento de projetos de manejo sustentável dos recursos naturais. Os resultados forneceram um conhecimento mais claro de quais dados são mais adequados para a região, como essas grandezas têm evoluem e quais os cenários futuros em relação a dinâmica dos fluxos de água e carbono no Mato Grosso.

**Palavras-chave:** Cobertura do solo, balanço hídrico, ciclo do carbono.

## ABSTRACT

Reliable satellite data and large-scale estimates of microclimate variables have been a growing need for microclimate studies in Mato Grosso. The region, which is home to three important Brazilian biomes, is undergoing an intense process of landscape modification. Understanding the effects of the modification of these areas of native vegetation on energy and mass fluxes, as well as their drivers, is of paramount importance for the development of natural resource management policies. This study evaluated estimates of soil water content (WS), evapotranspiration (ET) and gross primary productivity (GPP) in natural and anthropized formation areas in Mato Grosso. Estimates were obtained from reanalysis products, remote sensing, and the Thermal-Optical Trapezoid Model (TOTRAM). These data were also grouped into multi-model ensembles (MME) to generate new estimates. The results of the study are presented in two papers, the first evaluating the SM estimates and the second evaluating the ET and GPP estimates. Combining the SM, ET, and GPP products in the MME produced estimates with higher correlation, better agreement, and lower errors, while preserving the spatial variability of the products. The SSEBop, GLEAM, and PML products and the MME had the best validation performance, especially in the Pantanal. The research concluded that MME estimates provide more reliable and comprehensive data, allowing the study of regions that are difficult to access or more remote locations. These results also provide society with a safer alternative for developing sustainable natural resource management projects. The results have provided a clearer understanding of which data are most appropriate for the region, how these quantities have evolved, and what future scenarios exist in relation to the dynamics of water and carbon flows in Mato Grosso.

**Keywords:** Land cover, water balance, carbon budget.

## LISTA DE ILUSTRAÇÕES

Figura 1 - Principais sistemas meteorológicos que contribuem para a formação da ZCAS: Alta da Bolívia (AB), Vórtice Ciclônico de Altos Níveis (VCAN), Alta Subtropical do Atlântico Sul (ASAS) e frente estacionária. Fonte:(BUENO, 2022)..	1
Figura 2 - Precipitação média (mm; cores), vetor vento (m/s) em 925 hPa e linhas de corrente (linhas contínuas) em 200 hPa. As letra “A” e “C” em vermelho representam o anticiclone e o cavado, respectivamente. Fonte: (REBOITA et al., 2010).	2
Figura 3 - Anomalia de temperatura (a esquerda) e isóbaras em baixos níveis da atmosfera,	3
Figura 4 - Diagrama triangular VI-Ts, sendo VI o valor do índice de vegetação, Ts a temperatura da superfície e $\Phi$ um parâmetro que varia de 0 a 1,26. Extraído de (LI et al., 2009).	10
Figura 5 - Localização da Fazenda Experimental da Universidade Federal de Mato Grosso (UFMT), distribuição dos pontos de amostragem, localização da estação meteorológica na área de estudo e classificação da cobertura do solo, no estado de Mato Grosso, Brasil.	19
Figura 6 - Thermal-Optical Trapezoid Model (TOTRAM).	22
Figura 7 – Precipitação (Ppt; mm) mensal observada e normal climatológica (CN) da Ppt (CN) na Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso, em 2015 e 2016. Áreas em cinza representam o período seco e em branco o período chuvoso.	28
Figura 8 – Correlograma entre a precipitação acumulada mensal (Ppt; mm), Normalized Difference Vegetation Index (NDVI), temperatura de brilho (Tb; °C) e o conteúdo de água no solo (SM; $m^3m^{-3}$ ) na Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso, em 2015 e 2016. Foi usado o coeficiente de correlação de Spearman com significância de 95%, em que * indica valor $p < 0,05$ , ** valor $p < 0,01$ e *** indica valor $p < 0,001$ .	30
Figura 9 – Gráfico de dispersão entre o <i>Normalized Difference Vegetation Index</i> (NDVI) e a temperatura de brilho da superfície (Tb), estimados com imagens Landsat 8, e retas de regressão linear sobre os valores máximos (vermelho) e mínimos (azul) da Tb em função do NDVI, na Fazenda Experimental da Universidade Federal de Mato Grosso, em 2015 e 2016. O gradiente de cores do azul ao vermelho representa a menor (azul) e a maior (vermelho) densidade de pontos.	32
Figura 10 – Média anual e sazonal, e intervalo de confiança, do conteúdo de água no solo (SM; $m^3m^{-3}$ ) amostrado in situ (Observado) e estimado pelos produtos TOTRAM, SMOS, SMAP, AMSR2-A, AMSR2-D, ASCAT-A, ASCAT-B, ESA CCI, CLSM-RS, CLSM-S, NOAH-10 e NOAH-40.	34
Figura 11 – Coeficiente de correlação de Spearman (r), índice de Willmott (d), erro médio absoluto (MAE) e raiz do erro médio quadrado (RMSE) das estimativas do conteúdo de água no solo (SM; $m^3m^{-3}$ ) do modelo TOTRAM e dos produtos SMOS, SMAP, AMSR2-A, AMSR2-D, ASCAT-A, ASCAT-B, ESA CCI, CLSM-RZ,	

CLSM-S, NOAH10 e NOAH40, calculados em 11 diferentes coberturas de solo (CS, TC, PT, PM, MG, CD,AB, BN, CQ, CJ e PH) e para todas as coberturas (ALL), na Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso, em 2015 e 2016. ....	35
Figura 12 - Séries temporais do conteúdo de água no solo (SM; $m^3m^{-3}$ ) observado e estimado nas 11 coberturas de solo amostradas na Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso. A área sombreada representa o período seco. ....	37
Figura 13 – Coeficiente de correlação de Spearman (r), índice de Willmott (d), erro médio absoluto (MAE) e raiz do erro quadrático médio (RMSE) das estimativas do conteúdo de água no solo (SM; $m^3m^{-3}$ ) dos MMEs TOTAM & Monosat, TOTAM & Multisat, TOTAM & Multisource, TOTAM & MW Active, TOTAM & MW Passive and TOTAM & Better, calculados em 11 diferentes coberturas de solo (CS, TC, PT, PM, MG, CD,AB, BN, CQ, CJ e PH) e para todas as coberturas (ALL), na Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso, em 2015 e 2016. ....	40
Figura 14 – Estimativas do conteúdo de água no solo (SM; $m^3m^{-3}$ ) pelo Multi-model Ensemble TOTRAM & Better comparada com medidas em superfície em área de culturas de abacate (AB), banana (BN), caju (CJ), coco (CQ), manga (MG) e em áreas de cerradão (CD), cerrado stricto sensu (CS), pastagem humidícola (PH), pastagem mista (PM), pastagem brachiaria (PT), teca (TC) e para todas as coberturas (ALL) e respectivos valores do coeficiente de correlação de Spearman (r), índice de Willmott (d), erro médio absoluto (MAE; $m^3m^{-3}$ ) e raiz do erro quadrático médio (RMSE; $m^3m^{-3}$ ), na Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso, em 2015 e 2016. A linha diagonal preta determina a região de perfeito ajuste das estimativas. ....	41
Figura 15 - Estimativas do conteúdo de água no solo (SM) por meio do MME TOTAM & Better na Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso, em 2015 e 2016. ....	42
Figura 16 - Distribuição dos pontos de amostragem, biomas e classificação climática no estado de Mato Grosso, Brasil. ....	48
Figura 17 – Cobertura percentual do solo de formação florestal, formação de savana, floresta inundada, área úmida e pastagem dos biomas Amazônia (AMZ), Cerrado (CER) e Pantanal (PAN) em Mato Grosso, Brasil. Adaptado de (SOUZA et al., 2020). ....	48
Figura 18 – Médias da precipitação mensal acumulada na região dos pontos amostrais Alta Floresta (AFL), Sinop (SIN), Fazenda São Nicolau (FSN), Fazenda Arco-íris (FAI), Fazenda Miranda (FMI), Fazenda Experimental (FEX), Cambarazal (CAM), Baía das Pedras (BPE) e Baía das Pedras Eddy Covariance (NPW) e Normais Climatológicas (NC) na porção de Mato Grosso correspondente ao biomas Amazônia (AMZ), Cerrado (CER) e Pantanal (PAN). As médias da precipitação mensal acumulada correspondem ao período de 2001 a 2020. ....	60
Figura 19 – Média anual e sazonal, e intervalo de confiança, da evapotranspiração (ET; $mm\ dia^{-1}$ ) amostrada <i>in situ</i> (Ground) e estimada pelos produtos ERA5, FLDAS, SEBOP, PML, MODIS, GLEAM, Terra Climate, SEBAL e pela média ensemble	

desses produtos, nos biomas Amazônia (AMZ), Cerrado (CER) e Pantanal (PAN) em Mato Grosso no período de 2001 a 2020. ....	63
Figura 20 – Evapotranspiração (ET; mm dia <sup>-1</sup> ) estimada pelos produtos ERA5, FLDAS, SSEBop, PML, MODIS, GLEAM, Terra Climate e SEBAL, comparada com amostras <i>in situ</i> de ET, regressões lineares (linha tracejada) e valores de coeficiente de correlação de Spearman (r), índice de concordância de Willmott (d), erro médio absoluto (MAE; mm dia <sup>-1</sup> ) e raiz do erro quadrático médio (RMSE; mm dia <sup>-1</sup> ), na Amazônia (AMZ) de Mato grosso de 2001 a 2020. A linha preta diagonal contínua indica a região de perfeito ajuste das estimativas. ....	64
Figura 21 – Evapotranspiração (ET; mm dia <sup>-1</sup> ) estimada pelos produtos ERA5, FLDAS, SSEBop, PML, MODIS, GLEAM, Terra Climate e SEBAL, comparada com amostras <i>in situ</i> de ET, regressões lineares (linha tracejada) e valores de coeficiente de correlação de Spearman (r), índice de concordância de Willmott (d), erro médio absoluto (MAE; mm dia <sup>-1</sup> ), e raiz do erro quadrático médio (RMSE; mm dia <sup>-1</sup> ), no Cerrado (CER) de Mato Grosso de 2001 a 2020. A linha preta diagonal indica a região de perfeito ajuste das estimativas. ....	65
Figura 22 – Evapotranspiração (ET; mm dia <sup>-1</sup> ) estimada pelos produtos ERA5, FLDAS, SSEBop, PML, MODIS, GLEAM, Terra Climate e SEBAL, comparada com amostras <i>in situ</i> , regressões lineares (linha tracejada) e valores de coeficiente de correlação de Spearman (r), índice de concordância de Willmott (d), erro médio absoluto (MAE; mm dia <sup>-1</sup> ), e raiz do erro quadrático médio (RMSE; mm dia <sup>-1</sup> ), no Pantanal (PAN) de 2001 a 2020. A linha preta diagonal indica a região de perfeito ajuste das estimativas. ....	66
Figura 23 – Média anual e sazonal, e intervalo de confiança, da produtividade primária bruta (GPP; g C m <sup>-2</sup> dia <sup>-1</sup> ) amostrada <i>in situ</i> (Ground) e estimada pelos produtos ERA5, FLDAS, SSEBop, PML, MODIS, GLEAM, Terra Climate, SEBAL e pela média ensemble desses produtos, nos biomas Amazônia (AMZ), Cerrado (CER) e Pantanal (PAN) em Mato Grosso no período de 2001 a 2020. ....	67
Figura 24 – Produtividade primária bruta (GPP; g C m <sup>-2</sup> dia <sup>-1</sup> ) estimada pelos produtos MODIS AQUA, MODIS TERRA e PML, comparada com amostras <i>in situ</i> de ET na Amazônia (AMZ), no Cerrado (CER) e no Pantanal (PAN), com as respectivas regressões lineares (linha tracejada) e valores de coeficiente de correlação de Spearman (r), índice de concordância de Willmott (d), erro médio absoluto (MAE; g C m <sup>-2</sup> dia <sup>-1</sup> ), e raiz do erro quadrático médio (RMSE; g C m <sup>-2</sup> dia <sup>-1</sup> ), de 2001 a 2020. A linha preta diagonal indica a região de perfeito ajuste das estimativas. ....	68
Figura 25 – Histograma da evapotranspiração (ET; mm dia <sup>-1</sup> ) estimada pelas médias mensais dos produtos componentes <i>Multi-model Ensemble</i> (MME), na Amazônia (AMZ), no Cerrado (CER) e no Pantanal (PAN) de Mato Grosso de 2001 a 2020 ...	72
Figura 26 – Histograma da produtividade Primária Bruta (GPP; gC m <sup>-2</sup> dia <sup>-1</sup> ) estimada pelas médias mensais dos produtos componentes <i>Multi-model Ensemble</i> (MME), na Amazônia (AMZ), no Cerrado (CER) e no Pantanal (PAN) de Mato Grosso de 2001 a 2020. ....	73
Figura 27 – Evapotranspiração (ET; mm dia <sup>-1</sup> ) estimada pelas médias mensais dos produtos componentes <i>Multi-model Ensemble</i> (MME), na Amazônia (AMZ), no Cerrado (CER) e no Pantanal (PAN) de Mato Grosso de 2003 a 2019. ....	75

Figura 28 – Produtividade Primária Bruta (GPP;  $\text{gC m}^{-2} \text{ dia}^{-1}$ ) estimada pelas médias mensais dos produtos componentes *Multi-model Ensemble* (MME), na Amazônia (AMZ), no Cerrado (CER) e no Pantanal (PAN) de Mato Grosso de 2003 a 2019. ..76

Figura 29 – Medias anuais e modelo de tendência linear (*Trendline*), Tau de Kendall (Tau) e coeficiente de tendência de Sen (Sen' slope), obtidos pelos teste de Mann-Kendall e Teste de Mann-Kendall modificado sobre a evapotranspiração (ET;  $\text{mm dia}^{-1}$ ) e produtividade primária bruta (GPP;  $\text{gC m}^{-2} \text{ dia}^{-1}$ ) estimados pelo *Multi-model Ensemble* (MME), na Amazônia (AMZ), no Cerrado (CER) e no Pantanal (PAN) de Mato Grosso de 2003 a 2019. A simbologia \*\*\* indica valor p menor que 0,001, \*\* indica valor p menor que 0,01 e \* indica valor p menor que 0,05. ....76

## LISTA DE TABELAS

Tabela 1 – Descrição dos principais métodos de estimativa do conteúdo de água no solo por sensoriamento remoto e suas respectivas resoluções espaciais e referências. (Adaptado de (ZHANG; ZHOU, 2016)).....	6
Tabela 2 – Identificação e localização dos pontos de amostragem em diferentes coberturas do solo na Fazenda Experimental da Universidade Federal de Mato Grosso, Mato Grosso, Brasil. ....	20
Tabela 3 – Soil moisture products of Soil Moisture and Ocean Salinity (SMOS), Soil Moisture Active Passive (SMAP), Advanced Microwave Scanning Radiometer 2 (AMSR2-A and AMSR2-D), Advanced Scatterometer (ASCAT-A and ASCAT-D), European Space Agency's Climate Change Initiative for Soil Moisture (ESA CCI), Catchment Land Surface Model (CLSM-RZ and CLSM-S) e Noah Surface Model (NOAH10 e NOAH40), e suas respectivas resoluções espaciais (RE; km). ....	21
Tabela 4 – Multi-model ensembles (MME) elaborados com estimativas de SM do TOTRAM e dos produtos de SM de dados monossatélite (TOTRAM & Monosat), multissatélite (TOTRAM & Multisat), e mistos (TOTRAM & Multisource), dos produtos gerados a partir de dados de sensores de microondas ativos (TOTRAM & MW Active) e passivos (TOTRAM & MW Passive) e dos produtos que tiveram os melhores desempenhos na validação (TOTRAM & Better). ....	25
Tabela 5 – Classificação dos valores do coeficiente de correlação de Spearman e dos valores do índice de concordância de Willmott e os respectivos intervalos de classe. ....	27
Tabela 6 – Valor acumulado sazonal da precipitação (Ppt; mm) observada em 2015 e em 2016 e da normal climatológica (NC) nos períodos seco, chuvoso e anual na Fazenda Experimental da Universidade Federal de Mato Grosso.....	28
Tabela 7 – Parâmetros das regressões lineares entre o Normalized Difference Vegetation Index (NDVI) e a temperatura de brilho (Tb), intercep (i; °C) e slope (s) nas condições de borda seca (d) e borda úmida (w), estimados com imagens Landsat 8 para a Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso, em 2015 e 2016.....	33

Tabela 8 – Pontos amostrais nos biomas Amazônia, Cerrado e Pantanal, suas localizações, descrição dos seus ecossistemas e o período de amostragem de cada série de dados, em Mato Grosso. ....	51
Tabela 9 – Descrição dos equipamentos utilizados para medir as variáveis radiação solar global ( $R_g$ ), saldo de radiação ( $R_n$ ), temperatura do ar ( $T_a$ ), umidade relativa do ar ( $RH$ ), fluxo de calor no solo ( $G$ ), e suas respectivas alturas de instalação em cada ponto amostral. As descrições de cada abreviação estão na TABELA 8. ....	52
Tabela 10 – Descrição dos produtos das estimativas das variáveis evapotranspiração (ET) e produtividade primária bruta (GPP) e suas respectivas resoluções espaciais e referências. ....	54
Tabela 11 – Médias anuais e sazonais da precipitação acumulada nos pontos de amostragem de Alta Floresta (AFL), Sinop (SIN), Fazenda São Nicolau (FSN), Fazenda Arco-íris (FAI), Fazenda Experimental (FEX), Cambarazal (CAM) e Baía das Pedras (BPE e NPW), distribuídos na Amazônia (AMZ), Cerrado (CER) e Pantanal (PAN) e os valores da normal climatológica (NC) para esses biomas. ....	59
Tabela 12 – Coeficiente de correlação de Serman entre a Precipitação e a evapotranspiração (ET) e produtividade primária bruta (GPP) nos pontos de amostragem Alta Floresta (AFL), Sinop (SIN), Fazenda São Nicolau (FSN), Fazenda Arco-íris (FAI), Fazenda Experimental (FEX), Cambarazal (CAM) e Baía das Pedras (BPE e NPW), nos biomas Amazônia (AMZ), Cerrado (CER) e Pantanal (PAN). Os valores p representados por *** são menores que 0,001, ** menores que 0,01, * menores que 0,05 e – indica valores p maiores que 0,05. ....	61
Tabela 13 – Média, intervalo de confiança (ic), desvio padrão (SD) e coeficiente de assimetria da evapotranspiração (ET, mm/dia) e da produtividade primária bruta (GPP; $gC\ m^{-2}dia^{-1}$ ) estimada por <i>Multi-model Ensemble</i> (MME), nos biomas de Mato Grosso para os períodos chuvoso e seco de 2001 a 2020. ....	71

**LISTA DE ABREVIATURAS E SIGLAS**

<b>AB</b>	Abacate
<b>AFL</b>	Alta Floresta
<b>AMSR2</b>	<i>Advanced Microwave Scanning Radiometer for Earth Observing System</i>
<b>AMZ</b>	Amazônia
<b>ASCAT</b>	<i>Advanced Scatterometer</i>
<b>BN</b>	Bananal
<b>BPE</b>	Baía das Pedras
<b>BRM</b>	Método da razão de Bowen
<b>C3S</b>	<i>Copernicus Climate Change Service, Copernicus Climate Change Service</i>
<b>CAM</b>	Cambarazal
<b>CD</b>	Cerradão
<b>CER</b>	Cerrado
<b>CJ</b>	Caju
<b>CLSM</b>	<i>Global Land Data Assimilation System-Catchment Land Surface Model</i>
<b>CQ</b>	Coqueiro
<b>CS</b>	Cerrado <i>stricto sensu</i>
<b>ECMWF</b>	<i>European Centre for Medium-Range Weather Forecasts, European Centre for Medium-Range Weather Forecasts</i>
<b>ESA CCI</b>	<i>European Space Agency's Climate Change Initiative for Soil Moisture</i>
<b>ESPA</b>	<i>Center Science Processing Architecture</i>
<b>ET</b>	Evapotranspiração
<b>FAI</b>	Fazenda Arco-íris
<b>FEX</b>	Fazenda Experimental
<b>FMI</b>	Fazenda Miranda
<b>FPAR</b>	Fração de radiação fotossinteticamente ativa absorvida

<b>FSN</b>	Fazenda São Nicolau
<b>GMAO</b>	<i>Global Modeling and Assimilation Office</i>
<b>GPP</b>	Produtividade Primária Bruta
<b>GSM</b>	Umidade gravimétrica do solo
<b>IAF</b>	Índice de área foliar
<b>INMET</b>	Instituto Nacional de Meteorologia
<b>lat</b>	Latitude
<b>LE</b>	Fluxo de calor latente
<b>LIS</b>	Sistema de Informação Terrestre, Sistema de Informação Terrestre
<b>lon</b>	Longitude
<b>LSM</b>	Modelo de simulação da superfície
<b>LUE</b>	Eficiência de uso da luz
<b>MAE</b>	Erro médio absoluto
<b>MG</b>	Manga
<b>MK</b>	Mann-Kendall
<b>MME</b>	Multi-model ensemble
<b>Monosat</b>	Dados monossatélite
<b>Multisat</b>	Dados multissatélite
<b>Multisource</b>	Dados mistos
<b>MW</b>	microonda
<b>NASA</b>	<i>National Aeronautics and Space Administration</i>
<b>NC</b>	Normal climatológica
<b>NOAH</b>	<i>Global Land Data Assimilation System-Noah-simulated</i>
<b>NPW</b>	Eddy Covariance Pantanal
<b>PAN</b>	Pantanal
<b>PH</b>	Pastagem humidícola
<b>PM</b>	Pastagem Mista
<b>Ppt</b>	Precipitação
<b>PT</b>	Pastagem Tanzânia
<b>RH</b>	Umidade relativa do ar
<b>RMSE</b>	Raíz do erro quadrático médio
<b>RPPN</b>	Reserva Particular do Patrimônio

<b>SEBAL</b>	<i>Surface Energy Balance Algorithm for Land</i>
<b>SIN</b>	Sinop
<b>SM</b>	Conteúdo de água no solo
<b>SMAP</b>	<i>Soil Moisture Active Passive</i>
<b>SMOS</b>	<i>Soil Moisture and Ocean Salinity</i>
<b>TC</b>	Teca
<b>TOTRAM</b>	Thermal-Optical Trapezoid Model
<b>TRMM</b>	<i>Tropical Rainfall Measurement Mission</i>
<b>UFMT</b>	Universidade Federal de Mato Grosso
<b>USGS</b>	Serviço Geológico dos Estados Unidos
<b>ZCAS</b>	Zona de Convergência do Atlântico Sul

## LISTA DE SÍMBOLOS

<b>ALL</b>	Todas as coberturas do solo
<b><math>C_p</math></b>	Calor específico a pressão constante
<b>G</b>	Fluxo de calor no solo
<b>i</b>	Coefficiente linear
<b><math>I_{NDVI}</math></b>	Intervalo de NDVI
<b>m</b>	Índice m
<b><math>NDVI_{max}</math></b>	NDVI máximo
<b><math>NDVI_{min}</math></b>	NDVI mínimo
<b><math>NDVI_{par}</math></b>	NDVI paramétrico
<b>O</b>	Média do valor observado
<b><math>O_i</math></b>	Valor observado
<b><math>P_i</math></b>	Valor estimado
<b>r</b>	Coefficiente de correlação de Spearman
<b><math>R_g</math></b>	Radiação solar global
<b><math>R_n</math></b>	Saldo de radiação
<b>s</b>	Coefficiente angular
<b>T</b>	Temperatura média do ar
<b><math>T_a</math></b>	Temperatura do ar
<b><math>T_b</math></b>	Temperatura de brilho
<b><math>T_{bfil}</math></b>	Temperatura de brilho para filtragem
<b><math>T_{bmax}</math></b>	Temperatura de brilho máxima
<b><math>T_{bmin}</math></b>	Temperatura de brilho mínima
<b><math>\beta</math></b>	Razão de Bowen
<b><math>\Delta e</math></b>	Diferença vertical de pressão de vapor de água
<b><math>\Delta S</math></b>	Estoque de calor no espaço aéreo do dossel
<b><math>\Delta T</math></b>	Diferença vertical de temperatura
<b><math>\lambda</math></b>	Calor latente de vaporização

## SUMÁRIO

1. INTRODUÇÃO GERAL .....	1
1.1 Objetivo geral.....	2
1.2 Objetivos específicos.....	3
2. REVISÃO BIBLIOGRÁFICA .....	1
2.1 Climatologia de Mato Grosso .....	1
2.2 Estimativa do conteúdo de água no solo por sensoriamento remoto .....	4
2.3 Estimativa da evapotranspiração.....	7
2.4 Estimativa da Produtividade Primária Bruta e Eficiência no uso da água .	12
2.5 Multi-model ensembles .....	14
3. ARTIGO 1: ANÁLISE DE ALTERNATIVAS PARA A ESTIMATIVA DO CONTEÚDO DE ÁGUA NO SOLO EM ÁREAS DE MONOCULTURA E DE VEGETAÇÃO NATIVA EM MATO GROSSO.....	15
Resumo .....	15
3.1 Introdução .....	16
3.2 Material e métodos .....	19
3.2.1 Área de estudo.....	19
3.2.2 Precipitação e conteúdo de água no solo observado .....	20
3.2.3 Dados de satélite.....	21
3.2.4 Thermal-optical trapezoidal model .....	22
3.2.5 Parametrização do TOTRAM .....	23
3.2.6 Multi-model ensembles .....	24
3.2.7 Análise estatística .....	26
3.3 Resultados e discussão.....	28
3.3.1 Variáveis Micrometeorológicas .....	28

3.3.2	Parametrização do TOTRAM .....	31
3.3.3	Validação do TOTRAM e dos produtos de SM.....	33
3.4	Conclusões .....	43
4.	ARTIGO 2: VALIDAÇÃO DE ESTIMATIVAS DA EVAPOTRANSPIRAÇÃO E PRODUTIVIDADE PRIMÁRIA BRUTA PELA COMBINAÇÃO DE DIFERENTES PRODUTOS DE REANÁLISE NOS BIOMAS CERRADO, PANTANAL E AMAZÔNIA .....	45
	Resumo .....	45
4.1	Introdução .....	46
4.2	Materiais e método .....	47
4.2.1	Área de estudo.....	47
4.2.2	Dados de superfície .....	51
4.2.3	Dados de reanálise.....	53
4.2.4	Método da razão de Bowen.....	55
4.2.5	Multi-model ensembles .....	56
4.2.6	Análise estatística .....	57
4.3	Resultados e discussão.....	59
4.3.1	Variáveis micrometeorológicas.....	59
4.3.2	Validação e análise dos produtos de ET e GPP .....	62
4.4	Conclusões .....	78
5.	CONCLUSÕES GERAIS .....	79
6.	REFERÊNCIAS BIBLIOGRÁFICAS.....	80

## 1. INTRODUÇÃO GERAL

O estado de Mato Grosso, devido a sua localização geográfica e a sua extensão, tem elevada variação da disponibilidade energética e hídrica, proveniente da radiação solar e da precipitação, respectivamente (LATHUILLIÈRE *et al.*, 2012). A região também se destaca por abrigar três importantes biomas (Cerrado, Pantanal e Amazônia,) e uma variedade de espécies entre animais e plantas além de uma grande diversidade de fitofisionomias (VOURLITIS *et al.*, 2013). Por outro lado, a região tem passado por um acelerado processo de antropização que vem ocorrendo principalmente a partir da década de 1970, em que parte da cobertura do solo, antes ocupada por vegetação nativa, tem sido substituída, principalmente por áreas de cultivo agrícola ou por pastagem (SOUZA *et al.*, 2020).

Devido a esses fatores, o estado tem se tornado um importante foco de estudos que avaliam os impactos da mudança da cobertura do solo sobre os fluxos de energia e massa na superfície (PRIANTE-FILHO *et al.*, 2004; SABINO; SOUZA, 2023). Contudo, a investigação dos desdobramentos das mudanças perpassa por uma série de fenômenos, como os fluxos de vapor e carbono. Atualmente os estudos realizados na região se limitam a locais específicos e pouco abrangentes, devido principalmente a falta de dados de superfície confiáveis e que contemplem todo o estado.

Em todo o globo, novas metodologias de espacialização de diversos parâmetros biofísicos vêm sendo desenvolvidas, visando superar as atuais limitações, do ponto de vista operacional, em estudos ambientais e climáticos (DE OLIVEIRA *et al.*, 2016; HERSBACH *et al.*, 2020; RODELL *et al.*, 2004). Nas últimas décadas foram desenvolvidos produtos e modelos que fornecem estimativas espaço-temporais de variáveis como precipitação, conteúdo de água no solo (SM), evapotranspiração (ET) e Produtividade Primária Bruta (GPP) entre outras. Esses modelos utilizam como fonte principal dados de sensoriamento remoto, aos quais diferem pela faixa espectral, pelo tipo de sensor ou pelo número de bandas utilizadas (DIAS LOPES *et al.*, 2019; PELOSI *et al.*, 2020; SHI *et al.*, 2021).

Os dados gerados, conhecidos dos como produtos de reanálise, vêm sendo validados em diversas regiões do globo, viabilizando estudos em locais sem dados de superfície (DE OLIVEIRA *et al.*, 2016; DUBEY *et al.*, 2022; PELOSI *et al.*, 2020; ZHANG *et al.*, 2020). A validação dos produtos de reanálise viabiliza a sua utilização

regional, de modo que os resultados de estudos desenvolvidos com esses dados podem então ser utilizados como base confiável para o desenvolvimento de políticas públicas e relatórios ambientais, além de contribuir para o avanço das fronteiras de pesquisa em locais remotos ou de difícil acesso (LAIPELT *et al.*, 2021; PELOSI *et al.*, 2020; RODELL *et al.*, 2004).

A combinação de estimativas de diversos modelos e plataformas em *ensembles* vem sendo também estudada como alternativa as atuais limitações dos estudos microclimáticos (GUO *et al.*, 2007; XIA *et al.*, 2014). Os *Multi-model ensembles* (MME ) permitem combinar estimativas de diversos modelos produzindo novas estimativas que, em geral, carregam as tendências e padrões predominantes desses modelos (OLSON *et al.*, 2016). Os métodos de combinação dos MMEs variam entre os estudos, contudo a média tem sido a mais utilizada, pois garante a filtragem das características não concordantes entre os membros do ensemble enquanto reforça os comportamentos da maioria (DUAN *et al.*, 2007; LUO; WOOD, 2008). Alguns estudos têm obtido resultados em que os MMEs tiveram desempenho igual ou superior aos modelos que os compõem, uma vez que cada MME combina os diferentes aspectos da realidade de um mesmo fenômeno (GUO *et al.*, 2007; XIA *et al.*, 2014).

Em geral, a combinação de estimativas de um MME envolve dados com diferentes resoluções espaciais. Por isso, métodos como o resampling são utilizados, gerando um produto com resolução espacial igual ao produto de maior resolução do ensemble (GOOD, 2006). Por esse motivo, a combinação dos diversos produtos de dados micrometeorológicos é uma alternativa promissora para o estudo da variabilidade do conteúdo de água no solo e dos fluxos de massa em Mato Grosso (MARACAHIPES-SANTOS *et al.*, 2017).

## **1.1 Objetivo geral**

Avaliar estimativas do conteúdo de água no solo, evapotranspiração e Produtividade Primária Bruta em Mato Grosso, obtidas por reanálise e sensoriamento remoto, em áreas de formação natural e antropizadas, nos biomas Cerrado, Pantanal e Amazônia em Mato Grosso.

## **1.2 Objetivos específicos**

- i. Avaliar as estimativas do SM por meio da implementação do Thermal-Optical Trapezoid Model (TOTRAM ), aplicado a dados Landsat 8 em áreas de formação natural e antropizadas, no Cerrado Mato-Grossense;
- ii. Avaliar as estimativas do SM, ET e GPP de produtos e da combinação de desses produtos em ensembles em áreas de vegetação nativa e monoculturas, nos biomas Cerrado, Pantanal e Amazônia, em Mato Grosso;

## 2. REVISÃO BIBLIOGRÁFICA

### 2.1 Climatologia de Mato Grosso

Mato Grosso, devido a sua localização geográfica e a sua extensão, sofre influência de sistemas atmosféricos tanto de origem tropical quanto extratropical, que afetam principalmente a temperatura, a umidade relativa e o regime de chuvas, (LATHUILLIÈRE *et al.*, 2012; REBOITA *et al.*, 2010). Por essa razão a região apresenta uma diversidade climática considerável, influenciada localmente por fatores como sua localização geográfica, relevo e os sistemas meteorológicos. A precipitação em particular é governada pelos sistemas de larga Alta da Bolívia (AB), Zona de Convergência do Atlântico Sul (ZCAS) e Sistemas frontais (QUERINO *et al.*, 2017).

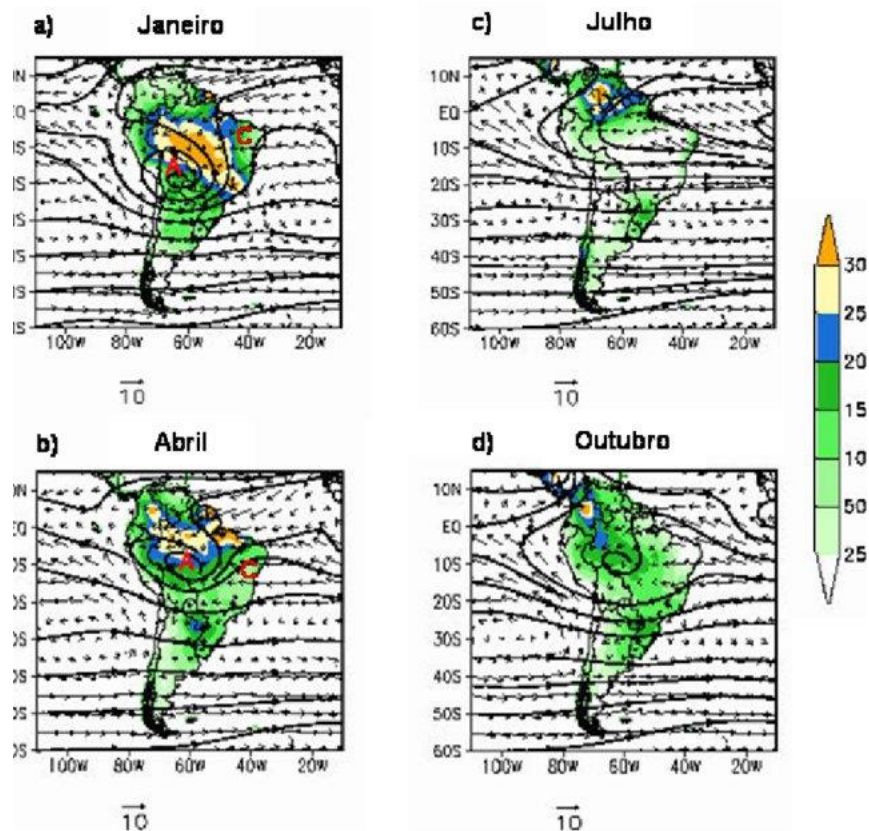
Figura 1 - Principais sistemas meteorológicos que contribuem para a formação da ZCAS: Alta da Bolívia (AB), Vórtice Ciclônico de Altos Níveis (VCAN), Alta Subtropical do Atlântico Sul (ASAS) e frente estacionária. Fonte:(BUENO, 2022)



A AB é caracterizada como um anticiclone em altos níveis da atmosfera, causado pelo aquecimento convectivo na superfície (DIAS *et al.*, 1983). Sua localização é definida sobre o altiplano boliviano durante o verão e depois sobre o interior do continente Sul Americano. A AB é responsável pelas ocorrências de chuva nas regiões Norte, Centro-oeste e parte do Nordeste brasileiro atingindo sua máxima intensidade entre os meses de dezembro e fevereiro e enfraquecendo entre abril e maio.

Em Mato Grosso, seu posicionamento no verão alinhado ao Cavado do Nordeste pode favorecer a ocorrência de episódios de ZCAS, o que eleva o volume de chuvas na região (QUERINO *et al.*, 2017).

Figura 2 - Precipitação média (mm; cores), vetor vento (m/s) em 925 hPa e linhas de corrente (linhas contínuas) em 200 hPa. As letra “A” e “C” em vermelho representam o anticiclone e o cavado, respectivamente. Fonte: (REBOITA *et al.*, 2010).

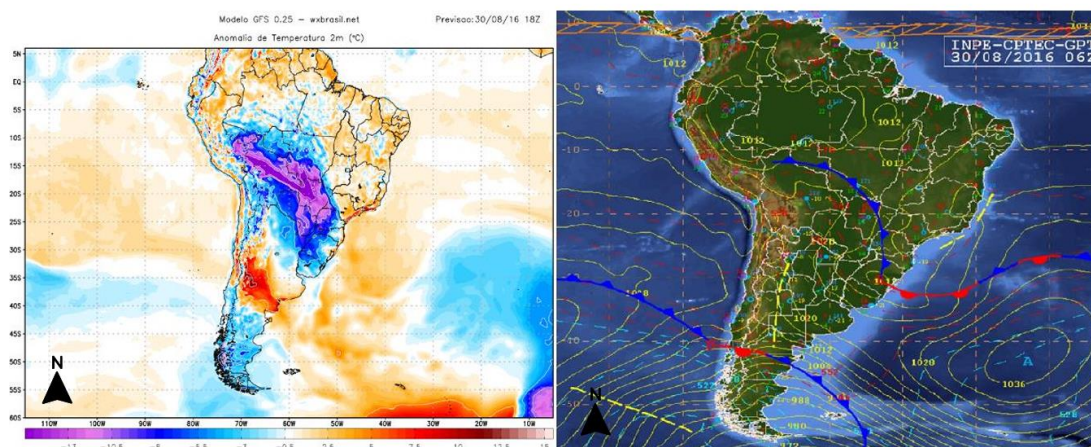


A Zona de Convergência do Atlântico Sul Ela é caracterizada por uma banda de nebulosidade e chuva orientada de noroeste para sudeste, estendendo-se da Amazônia até o sudoeste do Oceano Atlântico (ESCOBAR, 2014). Para a ocorrência das ZCAS, quatro fatores são considerados como indispensáveis: presença de instabilidade tropical formada pelo forte aquecimento continental, sistema frontal no oceano organizando a convecção amazônica no sentido noroeste-sudeste, jato de baixos níveis direcionado para o Sudeste do Brasil por causa da presença dos Andes que desvia os alísios e a advecção de umidade proveniente da região amazônica mediante a atuação do jato de baixos níveis (DE ABREU, 1998). Em Mato Grosso, a ZCAS é a principal responsável pela ocorrência de chuvas no verão.

A AB e a ZCAS podem ter sua atuação inibida devido à ocorrência de fenômenos de larga escala, como os bloqueios atmosféricos. O bloqueio atmosférico é configurado quando as condições meteorológicas associadas a este persistem durante vários dias (7 a 8 dias), podendo, em casos raros, prolongar-se até 15 dias, modificando os padrões de precipitação e temperatura numa ampla região (QUERINO et al., 2017). A circulação atmosférica de latitudes médias tem uma tendência a flutuar entre dois extremos: é caracterizada pela predominância do movimento zonal ou do movimento meridional. Quando um anticiclone permanece quase estacionário por um tempo, perturba a corrente zonal, impedindo a propagação dos sistemas para leste, nesta situação, o anticiclone recebe o nome de anticiclone de bloqueio (REBOITA et al., 2010).

Os sistemas frontais são caracterizados pela diferença de temperatura entre massas de ar de diferentes, em que uma avança sobre o continente sul-americano e atinge a região central e as vezes o sul da Amazônia (ARAÚJO et al., 2023). Os sistemas de frente têm origem na massa Polar atlântica, que é um sistema anticiclonal do Atlântico Sul, nas proximidades da Patagônia (BORSATO; MENDONÇA, 2015). Por essas razões, a massa de ar associada aos anticiclones é migratório de alta pressão, baixa temperatura e baixa umidade, sendo responsável pela friagem e por quedas de até 8°C/dia na temperatura do ar (QUERINO et al., 2017).

Figura 3 - Anomalia de temperatura (a esquerda) e isóbaras em baixos níveis da atmosfera, demonstrando um evento friagem ocorrido em agosto de 2016. Fonte (QUERINO, 2016)



Essas massas de ar periodicamente invadem o continente sul-americano, levando umidade colhida na superfície quente do mar que aumenta à medida que a massa avança sobre as regiões sul, sudeste, centro-oeste do Brasil, provocando chuvas mais ou menos abundantes. Durante o inverno, a partir de junho, os avanços tornam-se mais vigorosos, atingindo o norte de Mato Grosso (BORSATO; MENDONÇA, 2015).

## 2.2 Estimativa do conteúdo de água no solo por sensoriamento remoto

O conteúdo de água no solo (SM) afeta diretamente a assinatura espectral da superfície (DHARUMARAJAN *et al.*, 2024). Por essa razão, diversos modelos de estimativa do SM se baseiam nas mudanças da interação da radiação com a superfície, relacionando a refletância da superfície com o SM (ZHANG; ZHOU, 2016). Essa metodologia baseada no sensoriamento da superfície teve grandes avanços nas últimas décadas, com o lançamento de novos sensores e o desenvolvimento de técnicas computacionais como os modelos de reanálise (BROCCA *et al.*, 2017; RODELL *et al.*, 2004; XIA *et al.*, 2014). Do ponto de vista da Física, atualmente é possível identificar e compreender melhor os processos que afetam o balanço de energia e o balanço hídrico na superfície (ALLEN *et al.*, 2002; MCNALLY, 2018).

Os principais modelos de estimativa do SM são baseados na interação da superfície com a radiação de micro-ondas e nos efeitos da água no balanço de energia e na vegetação (BECK *et al.*, 2021; CHENG *et al.*, 2023; SCHMUGGE *et al.*, 1980; ZHANG; ZHOU, 2016). Os modelos baseados no sensoriamento remoto de micro-ondas são classificados de acordo com o tipo de dados que utilizam, entre dados de sensores ativos e sensores passivos. Atualmente existe uma série de sensores baseados em micro-ondas, como o passivo *Soil Moisture and Ocean Salinity* (SMOS) (KERR *et al.*, 2012), *Advanced Microwave Scanning Radiometer for Earth Observing System* (AMSR2) (PARINUSSA *et al.*, 2015), Fengyun (FY-3B/C/D, o ativo *Advanced Scatterometer* (ASCAT) (WAGNER *et al.*, 2013), Sentinel-1, *Advanced Land Observing Satellite-2* (ALOS-2), Gaofen-3 (GF-3) (ZENG *et al.*, 2023) e o ativo e passivo *Soil Moisture Active Passive* (SMAP) (ENTEKHABI *et al.*, 2010).

Os métodos de estimativa do SM baseados no efeito da água no balanço de energia são agrupados em métodos de inércia térmica, índices de temperatura e

métodos termal-ópticos, com suas vantagens e desvantagens. Os métodos de inércia térmica em geral consideram a resistência da superfície à mudança de temperatura a sua relação com o SM, obtida de forma quantitativa (FANG *et al.*, 2013, 2024; PRICE, 1985). A inércia térmica (P) pode ser expressa como:

$$P = \sqrt{\lambda\rho C} \quad (1)$$

onde  $\lambda$  é a condutividade térmica do solo,  $\rho$  é a densidade do solo e C é a capacidade térmica do solo. Os principais métodos baseados na inércia térmica são os modelos analítico físico, modelos baseados na amplitude e nas informações de fase da temperatura da superfície, os métodos de análise baseado em fontes de energia e métodos de sensoriamento remoto combinados com parâmetros físicos do solo. Em geral os modelos de estimativa do SM baseados na inércia térmica têm uma abordagem baseada em princípios físicos claros e menor quantidade de parâmetros em relação a outros métodos. Por outro lado, são limitados pela necessidade de dados auxiliares, como parâmetros físicos do solo, pela realização de aproximações e utilização de dados com baixa resolução espacial (ZHANG; ZHOU, 2016).

O método de índice de temperatura utiliza a informação da temperatura da superfície e a relaciona com o SM de um modelo matemáticos para as condições de solo exposto ou pouco vegetadas, pelo Índice de Temperatura da Diferença Normalizada (NDVI) (ZHANG; ZHOU, 2016), e solo vegetado, pelo Índice de Estresse Hídrico das Culturas (CWSI) (CHEN *et al.*, 2024).

O método termal-óptico utiliza dados de sensores na faixa do infravermelho e óptico. Essa abordagem parte de resultados de vários estudos que verificaram uma relação entre a assinatura espectral da superfície na faixa do visível e térmico e o seu conteúdo de água (BURDUN *et al.*, 2020; SADEGHI *et al.*, 2017; YANG *et al.*, 2015). Esses métodos, em geral exploram a relação espacial, no espaço termal x óptico, ou temporal entre essas grandezas (SONG *et al.*, 2013; YANG *et al.*, 2015). Entre os principais modelos estão o método do triângulo (CARLSON, 2007; RAWAT *et al.*, 2022), o método do trapézio (BURDUN *et al.*, 2020; SADEGHI *et al.*, 2017) e o método da informação temporal (LENG *et al.*, 2014).

Os métodos de estimativa do SM citados nessa revisão apresentam características que podem se apresentar como vantagem ou desvantagem entre si. Na Tabela 1 é apresentada uma descrição geral desses métodos, sua classificação,

vantagens e desvantagens. Os dados foram obtidos e adaptados de (ZHANG; ZHOU, 2016).

Tabela 1 – Descrição dos principais métodos de estimativa do conteúdo de água no solo por sensoriamento remoto e suas respectivas resoluções espaciais e referências. (Adaptado de (ZHANG; ZHOU, 2016)).

Categoria	Métodos	Vantagens	Desvantagens
Óptico	Métodos baseados em visível	Boa resolução espacial, multi-bandas disponíveis, tecnologia madura	Interferência da vegetação, efeitos noturnos e baixa resolução temporal
	Métodos baseados em infravermelho térmico	Boa resolução espacial, múltiplos satélites disponíveis	Interferência da vegetação, contaminação nublada, efeitos noturnos, baixa resolução temporal e efeitos atmosféricos
Micro-ondas passivo	Métodos (semi)empíricos, de base física	Alta precisão para superfícies de solo nu, ilimitada por nuvens e/ou condições diurnas, alta resolução temporal	Resolução espacial grosseira, influenciada pela cobertura vegetal e rugosidade superficial
Micro-ondas ativo	Métodos (semi)empíricos, de base física	Resolução espacial fina, ilimitada por nuvens e/ou condições diurnas	influenciado pela rugosidade superficial e quantidade de cobertura vegetal, resolução temporal grosseira
Métodos sinérgicos	Infravermelho Óptico & Térmico	Alta resolução espacial, implementação simples e direta	limitado a condições sem nuvens e diurnas, baixa resolução temporal, baixa profundidade de penetração
	MW ativo e passivo	Melhor resolução temporal e espacial	Dimensionamento e validação de SMC precisam de cuidado, diferentes profundidades de medição de SMC
	MW & óptico	Minimização dos efeitos da vegetação e da rugosidade superficial	Dimensionamento e validação de SMC precisam de cuidado, diferentes profundidades de medição de SMC

### 2.3 Estimativa da evapotranspiração

A evapotranspiração é um importante componente do balanço hídrico da superfície sendo o resultado dos processos de evaporação e transpiração da superfície, os quais dependem diretamente do balanço energético da superfície (DONG *et al.*, 2016; LI *et al.*, 2009). A oferta energética, a cobertura da superfície e a disponibilidade hídrica no solo são os fatores que mais afetam o balanço de energia e consequentemente a evapotranspiração (DIAS LOPES *et al.*, 2019).

A modificação da cobertura da superfície afeta os fluxos de energia e causa mudanças na assinatura espectral da superfície. Dessa forma, informações sobre a dinâmica energética e a evapotranspiração na superfície são obtidas diversos modelos e técnicas de sensoriamento remoto. Atualmente existem vários modelos de estimativa da evapotranspiração, os quais se diferenciam pelo tipo de dados utilizados e por uma interpretação particular da relação entre os fluxos de energia e matéria e a oferta hídrica no solo. Em geral, essa relação não é totalmente caracterizada, além de que cada microclima apresenta características próprias, exigindo diferentes abordagens no estudo do balanço de energia.

Diversos estudos, por sua vez, têm buscado validar as estimativas obtidas desses modelos (ANGELINI *et al.*, 2021; DEGANO *et al.*, 2021; DIAS LOPES *et al.*, 2019; JIANG *et al.*, 2019; SHI *et al.*, 2021). Atualmente os modelos mais utilizados são o *Surface Energy Balance Index* (SEBI), o *Surface Energy Balance System* (SEBS), o *Simplified Surface Energy Balance Index* (S-SEBI), o *Surface Energy Balance Algorithm for Land* (SEBAL), o *Mapping Evapotranspiration at High Resolution and with Internalized Calibration* (METRIC), o *Two-Source Models* (TSM), o Método Triângular VI-TS, o Método Trapezoidal VI-TS e os métodos de assimilação de dados.

O *Surface Energy Balance Index* (SEBI) é baseado no Índice de Estresse Hídrico da Cultura (CWSI). A evaporação relativa é determinada com os extremos do balanço de energia de superfície, em que limites inferiores e superiores teóricos na superfície e diferença de temperatura da superfície determinam a região seca, pela temperatura máxima, em que a evaporação é assumida como zero, e a região úmida, como máxima taxa evaporativa, determinada pela temperatura mínima (LI *et al.*, 2009). Temperatura da superfície é estimada usando imagens de satélites na região do infravermelho térmico para cada pixel (LIOU; KAR, 2014). Algumas modificações

foram propostas por outros autores, com o objetivo de explicar a influência do albedo e da aerodinâmica na taxa evaporativa (MENENTI; CHOUDHURY, 1993).

O *Surface Energy Balance System* (SEBS) e o *Simplified Surface Energy Balance Index* (S-SEBI), são algoritmos modificados gerados a partir do SEBI, diferenciando pela forma de definir os limites seco (calor latente mínimo e calor sensível máximo) e úmido (calor latente máximo e calor sensível mínimo). Esses modelos partem da suposição de que não há mudança nas condições atmosféricas (principalmente a energia disponível na superfície) no espaço, fazendo das variações horizontais de superfície suficientes para garantir a existência de limites secos e úmidos na área de estudo. O SEBS utiliza o modelo dinâmico para determinar a rugosidade térmica e a teoria de Similaridade Atmosférica em Massa para escala Camada Limite Planetária (PBL) e a similaridade da Camada Superficial Atmosférica (ASL) de Monin-Obukhov para escalonamento de camadas superficiais. O S-SEBI utiliza o contraste entre uma temperatura de brilho superficial máxima para limite seco e uma temperatura de brilho superficial mínima para limite úmido para a determinação dos fluxos de calor sensível e fluxo de calor latente (ROERINK *et al.*, 2000). A fração evaporativa no S-SEBI é delimitada pela interpolação da temperatura de brilho superficial entre a temperatura superficial máxima e a temperatura superficial mínima nos limites seco e úmido, respectivamente (LIOU; KAR, 2014).

As entradas para o SEBS incluem parâmetros terrestres derivados de dados de sensoriamento remoto e medições meteorológicas baseadas no solo, como temperatura da superfície terrestre, IAF, cobertura vegetal fracionada, albedo, velocidade do vento, umidade e temperatura do ar. Por outro lado, o S-SEBI depende apenas dos parâmetros de temperatura e reflectância da superfície (albedo) derivados de dados de sensoriamento remoto (LI *et al.*, 2009).

O SEBAL tem como principal característica o processo numérico iterativo e baseado em *feedback* que resultando na dedução dos fluxos de radiação, calor e evaporação. No SEBAL, são tomadas duas temperaturas do ar de referência, uma próxima à superfície e outra em uma altura maior. Para determinar a diferença de temperatura do ar próximo à superfície ( $dT$ ) para cada pixel, o SEBAL assume a existência de uma relação linear entre  $dT$  e a temperatura da superfície ( $T_s$ ). São usadas condições de contorno sobre  $dT$ , dadas pela teoria aerodinâmica, nos extremos nos

pontos seco (quente) e úmido (frio), obtendo os coeficientes da relação linear entre  $dT$  e  $T_s$  (WATERS *et al.*, 2002).

O METRIC foi proposto em 2007, com a mesma metodologia do SEBAL, mas buscando reduzir as incertezas em relação as estimativas do saldo de radiação ( $R_n$ ) e da temperatura da superfície ( $T_s$ ), devido a topografia. Dessa forma, o  $R_n$  e a  $T_s$  são corrigidos topograficamente usando um Modelo Digital de Elevação. Além disso, o METRIC difere do SEBAL pelo cálculo do fluxo de calor sensível ( $H$ ), em que considera que a taxa de evapotranspiração ( $ET$ ) está cerca de 5% acima do padrão, devido à grande população de campos, em que alguns terão uma superfície de solo úmido sob um dossel de vegetação completa que tenderá a aumentar a taxa total de  $ET$  (ALLEN *et al.*, 2007; GARCÍA-SANTOS *et al.*, 2022).

De modo geral, as distinções entre o METRIC e o SEBAL são citadas abaixo (LIOU; KAR, 2014):


- No pixel molhado, METRIC não assume  $H_{\text{molhado}} = 0$  ou  $LE_{\text{molhado}} = (R_n - G)$ , sendo  $G$  o fluxo de calor no solo. Em vez disso, um balanço diário de água superficial do solo é usado para garantir que a  $ET$  seja zero e definido como  $1,05ET_r$  em pixels quentes e úmidos, respectivamente.  $ET_r$  é a  $ET$  de referência horária calculada usando a equação padronizada ASCE Penman-Monteith;
- No METRIC, os pixels úmidos são selecionados em um ambiente agrícola, enquanto por outro lado os pixels frios são selecionados com base em características biofísicas semelhantes à cultura de referência;
- Em vez da fração evaporativa real, a interpolação (extrapolação) do  $ET$  instantâneo para o valor diário é baseada na  $ET_rF$  (razão entre o  $ET$  instantâneo e o  $ET_r$  de referência e é calculada a partir dos dados da estação meteorológica no tempo de passagem do satélite).

No modelo TSM o balanço de energia é obtido considerando os fluxos energético nas fontes convectiva e radiativa, com foco na relação entre a temperatura radiométrica e aerodinâmica, de modo que o  $LE$  é obtido de maneira residual. O  $R_n$  é separado por fontes de solo e vegetação, e cada fonte segue a equação do balanço de energia própria (GARCÍA-SANTOS *et al.*, 2022). O  $LE$  do dossel é calculado usando a equação de Priestley-Taylor (PRIESTLEY; TAYLOR, 1972). Nesse método a temperatura do dossel é obtida de maneira iterativa e residual das temperaturas do solo

e da superfície. Pela escolha de utilizar a equação de Priestley-Taylor, o TSM superestima o fluxo de calor latente do dossel em condições de estresse hídrico e a evaporação negativa do solo (LIOU; KAR, 2014). Por outro lado, o método tem como vantagem a dispensabilidade de correções atmosféricas precisas, estimativas de emissividade, uso de sensores calibrados com alta precisão e informações terrestres adicionais como as exigidas em um modelo de fonte única (LI *et al.*, 2009).

Os métodos do triângulo e do trapézio de distribuição VI-Ts são construídos a partir de um embasamento biofísico de que a evaporação de água no solo e a transpiração das plantas depende da temperatura da superfície e da densidade da vegetação no local estudado (LAMBIN; EHRLICH, 1996). O modelo do triângulo pode ser simplificado na Figura 4, assumindo que em um gráfico de dispersão de séries temporais da temperatura da superfície e de algum índice de vegetação da superfície se deve observar que os pontos se distribuem numa região delimitada por um triângulo. Nessa região a aresta superior corresponde a borda de pontos em locais com pouca disponibilidade hídrica, de modo que a variação de temperatura dependa apenas da cobertura de vegetação. A borda inferior corresponde aos locais com máxima disponibilidade hídrica, de modo que a temperatura da superfície é constante em relação a densidade de vegetação (GARCÍA-SANTOS *et al.*, 2022).

Figura 4 - Diagrama triangular VI-Ts, sendo VI o valor do índice de vegetação, Ts a temperatura da superfície e  $\Phi$  um parâmetro que varia de 0 a 1,26. Extraído de (LI *et al.*, 2009).



O fluxo de calor latente é calculado no método do triângulo partindo da equação de Priestley-Taylor e da relação triangular entre VI-Ts (PRIESTLEY; TAYLOR, 1972). O método do trapézio parte do entendimento de que a vegetação pode sofrer estresse hídrico, mesmo em locais com alta cobertura vegetal. Dessa forma, não haveria um ponto de intersecção entre as bordas seca e úmida, ou seja, os efeitos sobre a evapotranspiração numa superfície bem regada e numa superfície bem vegetada não seriam os mesmos (MORAN *et al.*, 1994). O Método do trapézio é baseado no Índice de Déficit Hídrico (IDH), que avalia as taxas de evapotranspiração tanto de áreas de cobertura total como de parcialmente vegetadas (GARCÍA-SANTOS *et al.*, 2022). Por fim a estimativa de ET é realizada pela interpolação entre a ET potencial na borda úmida e na borda seca (JIANG *et al.*, 2019).

As constantes melhoria nos conceitos físicos subjacentes aos processos terrestres relacionados aos fluxos de massa e energia na superfície, forneceram base teórica para o desenvolvimento de modelos de simulação da superfície (LSM). Além disso, o desenvolvimento computacional ocorrido nas últimas décadas, forneceu capacidade computacional para simular os fenômenos complexos descritos nos LSM (CHEN *et al.*, 2013). Atualmente, o aumento no poder de processamento, devido ao progresso computacional, e a facilidade de acesso aos dados estão permitindo que simulações globais, realizadas inicialmente apenas com supercomputadores, possam agora ser realizadas rotineiramente e com menos tempo (DONG *et al.*, 2016; MUELLER *et al.*, 2011; OLIOSO *et al.*, 1999).

Os métodos de estimativa da evapotranspiração por assimilação de dados são também chamados de métodos de reanálise. Os produtos de reanálise são gerados por LSM a partir de produtos de dados observacionais baseados em satélite e na superfície, usando técnicas avançadas de modelagem da superfície terrestre e de assimilação de dados (RODELL *et al.*, 2004). Dentre os diversos produtos pode-se citar o ERA5, FLDAS e PML.

O ERA5 foi desenvolvido e implementado pelo *European Centre for Medium-Range Weather Forecasts* (ECMWF) dentro do *Copernicus Climate Change Service* (C3S), sendo a quinta geração de reanálise desde 1979 (HERSBACH *et al.*, 2020). O ERA5 foi lançado em 2017 com um sistema mais avançado de assimilação e esquemas de parametrização em relação as gerações anteriores, além de uma maior resolução

espaço-temporal e uma quantidade maior de parâmetros (mais de 240 parâmetros) (JIANG *et al.*, 2021). Os sistemas FLDAS são instâncias personalizadas do Sistema de Informação Terrestre da NASA (LIS ) que derivam em três sistemas de modelagem, FLDAS-Global (MCNALLY *et al.*, 2017), FLDAS-Ásia Central (MCNALLY *et al.*, 2022) e FLDAS-Forecast (HAZRA *et al.*, 2023). Os dados FLDAS possuem um período de cobertura de 1981 até o presente, sendo aplicados principalmente em estudos de monitoramento de seca agrícola e caracterização de seca (KHAKI *et al.*, 2018; MCNALLY *et al.*, 2017). O modelo Penman-Monteith-Leuning (PML) foi desenvolvido a partir da proposta de estimativa da condutância superficial, que descreve a condutância dossel-solo ao fluxo de água (LEUNING *et al.*, 2008). O PML foi proposto em 2008 e desde então tem passado por modificações, chegando a versão PML-V2, em que suas estimativas são baseadas em dados MODIS (ZHANG *et al.*, 2019).

#### **2.4 Estimativa da Produtividade Primária Bruta e Eficiência no uso da água**

A fotossíntese é o processo que o CO<sub>2</sub> atmosférico é assimilado pelas plantas, sendo fundamental para a manutenção dos ecossistemas terrestres. Nesse processo, parte da água da planta é perdida para a atmosfera nos estômatos das folhas. A absorção bruta de carbono pelas plantas é denominada produtividade primária bruta (GPP) e a taxa de absorção de carbono por unidade de perda de água é denominada por eficiência no uso da água (WUE).

A estimativa do GPP é realizada principalmente por sensoriamento remoto, que fornece a possibilidade de estudar diversos ecossistemas, sem a necessidade de instalação de sensores in loco. A WUE pode ser calculada diretamente pela razão entre o GPP e a ET ou estimada por modelos de sensoriamento remoto específicos (PAVÃO, 2021; ZHOU *et al.*, 2017). Atualmente, existem diversos modelos de estimativa do GPP e WUE, dois quais se pode os modelos de GPP MODIS-TERRA (RANJAN; GORAI, 2022), MODIS-AQUA (RUNNING *et al.*, 2015) e PML (ZHANG *et al.*, 2019) e os modelos de *WUE Community Land Model* versão 4.0 (CLM4) (KIM *et al.*, 2021), *Dynamic Land Ecosystem Model* (DLEM) (PAN *et al.*, 2015), e *Integrated Science Assessment Model* (ISAM) (JAIN *et al.*, 2009).

Os produtos MOD17A2H e MYD17A2H estimam a produtividade primária bruta (GPP) a partir de duas fontes de dados de entrada: dados meteorológicos, obtidos dos dados de reanálise do *Global Modeling and Assimilation Office* (GMAO), e dados de fração de radiação fotossinteticamente ativa absorvida (FPAR) fornecidos pelos produtos MOD15A2H e MYD15A2H, respectivamente (WANG et al., 2017; ZHANG et al., 2023). O algoritmo GPP do MODIS é um modelo semi-empírico que parte de uma abordagem da eficiência de uso da luz (LUE), em que o GPP é um produto da radiação fotossinteticamente ativa absorvida (YANG et al., 2023; ZHANG et al., 2019, 2023). As estimativas de GPP no modelo PML-V1 utilizam o modelo de condutância do dossel ( $G_c$ ) aplicado à equação de Penman-Monteith (LEUNING et al., 2008). No PML-v2, o  $G_c$  é utilizado para acoplar a ET ao GPP, de modo que o déficit de pressão de vapor (VPD) é inserido para limitar o GPP (PEI et al., 2020).

O CLM4 é um modelo prognóstico resultado da interação entre mecanismos biogeoquímicos e biofísicos fundamentais dos ecossistemas terrestres. Nesse modelo é acoplada a biofísica do CLM e a biogeoquímica carbono-nitrogênio do Biome-BGC4.1.2 (Thornton e Rosenbloom 2005). Como resultado são obtidas estimativas de variáveis relacionadas a água, energia, carbono e nitrogênio nos diversos ecossistema (BONAN et al., 2011).

O DLEM é um Modelo que tem a capacidade de estimar temporal e espacialmente os fluxos de água, gases de efeito estufa, dinâmica do Carbono e Nitrogênio no solo e corpos d'água em ecossistemas terrestres, e a descarga fluvial associada, exportação fluvial de Carbono e Nitrogênio da terra para o oceano (WANG et al., 2020). Sua metodologia parte da integração de processos a fim de obter dados sobre os padrões climáticos em cada ecossistema, identificando os efeitos das mudanças globais sobre eles (PAN et al., 2015). O *Integrated Science Assessment Model* (ISAM) simula fluxos de C de e para diferentes partes da biosfera terrestre, considerando os aspectos pedológicos como o tipo de solo, cobertura do solo e mudança no uso do solo (JAIN et al., 2009). O ISAM contabiliza as reservas de C, as distribuindo em serapilheira metabólica acima do solo, serapilheira estrutural acima do solo, serapilheira de plantas decomponível abaixo do solo, serapilheira de plantas abaixo do solo resistente, solo microbiano acima do solo, solo húmus jovem, solo microbiano abaixo do solo e solo de húmus estabilizado (JAIN et al., 2006).

## 2.5 Multi-model ensembles

A combinação de estimativas de diversos modelos e plataformas em ensembles vem sendo utilizada como alternativa as atuais limitações dos modelos de estimativa de parâmetros ambientais (GUO *et al.*, 2007; XIA *et al.*, 2014). Os *Multi-model ensembles* (MME) permitem combinar estimativas de diversos modelos produzindo novas estimativas que, em geral, carregam as tendências e padrões predominantes desses modelos (OLSON *et al.*, 2016). Os dados produzidos pelos MMEs são aplicados em diversos estudos, sobretudo em projeções climáticas (TEBALDI; KNUTTI, 2007), previsões hidrológicas (DUAN *et al.*, 2007) e estudos atmosféricos (GILLET *et al.*, 2002).

Os métodos de combinação dos MMEs variam entre os estudos, contudo a média tem sido a mais utilizada, pois garante a filtragem das características não concordantes entre os membros do ensemble enquanto reforça os comportamentos da maioria (DUAN *et al.*, 2007; LUO; WOOD, 2008; SEMENOV; STRATONOVITCH, 2010). Contudo, alguns autores defendem que a implementação da média sem uma devida manipulação prévia dos dados de entrada pode aumentar os erros das estimativas (KIOUTSIUKIS; GALMARINI, 2014). Por exemplo, os diversos produtos que podem compor um MME apresentam diferentes resoluções espaciais, sendo necessária a aplicação de um processamento que padronize as suas resoluções. Por isso, métodos como o resampling são utilizados, gerando um produto com resolução espacial igual ao produto de maior resolução do ensemble (GOOD, 2006).

### 3. ARTIGO 1: ANÁLISE DE ALTERNATIVAS PARA A ESTIMATIVA DO CONTEÚDO DE ÁGUA NO SOLO EM ÁREAS DE MONOCULTURA E DE VEGETAÇÃO NATIVA EM MATO GROSSO

#### Resumo

O conteúdo de água no solo é um parâmetro fundamental para a compreensão dos ecossistemas do Cerrado e dos seus ciclos de matéria e energia na região. A falta dessas informações tem sido uma das principais causas da exploração inadequada desse recurso. Contudo, os principais produtos que fornecem dados da dinâmica e distribuição do conteúdo de água no solo não são aplicáveis em estudos de microescala, por conta das suas baixas resoluções espaciais. No presente estudo foram avaliadas estimativas do conteúdo no solo em áreas de pastagem não nativa, formações naturais e culturas agrícolas no Cerrado de Mato Grosso, visando identificar quais dados são mais confiáveis e abrangentes. As estimativas foram obtidas de produtos gerados por dados de satélites orbitais, dotados de sensores de radiação ativa e passiva, dados mistos e do *Thermal-Optical Trapezoid Model* (TOTRAM), além da combinação de dessas estimativas em *Multi-model ensembles* (MME). Houve correlação significativa entre o conteúdo de água no solo observado, o índice de vegetação da diferença normalizada e a temperatura de brilho da superfície, com o mesmo padrão de sazonalidade para o conteúdo de água no solo e o índice de vegetação enquanto a temperatura teve padrão invertido. As estimativas dos produtos Soil Moisture and Ocean Salinity (SMOS), Catchment Land Surface Model (CLSM-RZ e CLSM-S) e Noah Surface Model (NOAH10 e NOAH40) apresentaram maior desempenho. Os produtos de satélite combinados com o TOTRAM em multi-model ensemble (MME) produziram estimativas com menores erros, maior correlação, concordância e resolução espacial, demonstrando a confiabilidade dos dados de conteúdo de água no solo e viabilizando a sua aplicação em estudos ambientais e no desenvolvimento de políticas de gestão de recursos naturais.

**Palavras-chave:** Savana brasileira, sensoriamento remoto, disponibilidade hídrica.

### 3.1 Introdução

O Cerrado brasileiro, um dos ecossistemas mais diversos do mundo, se destaca pela sua extensão de aproximadamente 200 milhões de hectares e por abrigar uma variedade de espécies endêmica entre animais e plantas além de uma grande diversidade de fitofisionomias que são condicionadas a variação espaço-temporal da fertilidade do solo e do conteúdo de água no solo (GLATZLE *et al.*, 2021; IBGE, 2024; MARQUES *et al.*, 2020; MMA, 2021; VOURLITIS *et al.*, 2013). Por outro lado, a região tem passado por um acelerado processo de antropização que vem ocorrendo principalmente a partir da década de 1970. Estimativas apontam que atualmente entre 45% e 50% da cobertura do solo no Cerrado já foi substituída, principalmente por áreas de cultivo agrícola ou por pastagem (EMBRAPA, 2018; MACHADO *et al.*, 2020; SOUZA *et al.*, 2020). Por essa razão, o Cerrado tem despertado interesse tanto do ponto de vista ambiental, devido ao risco de extinção da fauna e flora, quanto econômico, que busca aumentar a eficiência do sistema de produção agrícola.

Um dos principais impactos da exploração do solo no Cerrado tem sido a mudança na variabilidade do conteúdo de água no solo (SM) (FERREIRA *et al.*, 2012). A exploração inadequada do SM no cerrado, principalmente devido à falta de dados sobre a dinâmica do recurso, afeta a disponibilidade hídrica no solo e a produtividade, causando uma expansão das áreas de cultivo para garantir a manutenção da produtividade (ALTHOFF *et al.*, 2021b; RODRIGUES *et al.*, 2020). Apesar de certas regiões do Cerrado serem abundantes em água, muitas das suas bacias já enfrentam disputas crescentes pelo uso desse recurso, causadas principalmente pela expansão inapropriadas das atividades agropecuárias, que geralmente ocorre com planejamento deficiente (ALTHOFF *et al.*, 2021a; FERRARINI *et al.*, 2019; POUSA *et al.*, 2019; SANTOS; NAVAL, 2021).

Estudos têm buscado estabelecer uma relação precisa entre a assinatura espectral da superfície e o SM por sensoriamento remoto em diversas regiões do globo (AMBROSONE *et al.*, 2020; BEZERRA *et al.*, 2013; MARACAHIPES-SANTOS *et al.*, 2017; SADEGHI *et al.*, 2017; ZHANG; ZHOU, 2016; ZHANG *et al.*, 2020). Foram desenvolvidos produtos com estimativas do SM por sensoriamento remoto seguindo diferentes caminhos, aos quais diferem pela faixa espectral, pelo tipo de

sensor ou pelo número de bandas utilizadas (FILION *et al.*, 2016; MINACAPILLI *et al.*, 2009; SHI *et al.*, 2021; ZHANG; ZHOU, 2016). Outros estudos desenvolveram produtos que utilizam dados de superfície assimilados em modelo ideais de estado e fluxos na superfície, com a proposta de obter estimativas do SM mais precisas (HU *et al.*, 2021; YANG *et al.*, 2017; ZHANG *et al.*, 2021). Esses produtos vêm sendo implementados por estudos em diversos locais, com destaque para os produtos do *Soil Moisture and Ocean Salinity* (SMOS ) (KERR *et al.*, 2012), *Soil Moisture Active Passive* (SMAP ) (ENTEKHABI *et al.*, 2010), *Advanced Microwave Scanning Radiometer for Earth Observing System* (AMSR2 ) (PARINUSSA *et al.*, 2015), *Advanced Scatterometer* (ASCAT ) (WAGNER *et al.*, 2013), *European Space Agency's Climate Change Initiative for Soil Moisture* (ESA CCI ) (DORIGO *et al.*, 2017; GRUBER *et al.*, 2019), *Global Land Data Assimilation System-Catchment Land Surface Model* (CLSM) (HU *et al.*, 2021) e do *Global Land Data Assimilation System-Noah-simulated* (NOAH ) (ZHANG *et al.*, 2021).

Apesar dos grandes avanços atingidos por esses projetos, a maioria não é aplicável em estudos de pequena e micro escala, que demandam dados com resolução espacial menor que 1 km para caracterizar os gradientes de umidade no solo entre diferentes microclimas, como na agricultura ou na micrometeorologia, (BECK *et al.*, 2021; ZHANG; ZHOU, 2016). Além disso, a aplicabilidade desses produtos é restrita aos locais em que foram desenvolvidos, sendo necessária sua validação em outras regiões (FANG *et al.*, 2021; XU; FREY, 2021). Por essa razão, é necessário que se busque métodos que preservem os avanços alcançados pelos produtos de SM enquanto avaliam alternativas que deem conta da demanda por dados de SM com maior resolução espacial.

O *Thermal-Optical Trapezoid Model* (TOTRAM) é um método de estimativa do SM que utiliza dados de satélite de diversas resoluções espaciais, incluindo satélites de alta resolução. O TOTRAM relaciona a densidade de biomassa vegetal viva, por meio do *Normalized Difference Vegetatio Index* (NDVI), com a temperatura da superfície, por meio da temperatura de brilho (Tb ) (BURDUN *et al.*, 2020; SADEGHI *et al.*, 2017). Nesse modelo o SM é estimado por meio da parametrização dos cenários de solo seco vegetado, solo seco não vegetado, solo úmido vegetado e solo úmido não vegetado, extraída da relação linear entre o NDVI e a Tb (YANG *et al.*, 2015). Essa

metodologia tem se destacado entre os outros modelos principalmente por ser simples do ponto de vista matemático, por demandar baixa carga computacional e por possibilitar estimativas do SM com alta resolução espacial (SADEGHI *et al.*, 2017).

A combinação de estimativas de diversos modelos e plataformas em ensembles vem sendo também estudada como alternativa as atuais limitações dos modelos de estimativa de SM (GUO *et al.*, 2007; XIA *et al.*, 2014). Os *Multi-model ensembles* (MME) permitem combinar estimativas de diversos modelos produzindo novas estimativas que, em geral, carregam as tendências e padrões predominantes desses modelos (OLSON *et al.*, 2016). Os métodos de combinação dos MMEs variam entre os estudos, contudo a média tem sido a mais utilizada, pois garante a filtragem das características não concordantes entre os membros do ensemble enquanto reforça os comportamentos da maioria (DUAN *et al.*, 2007; LUO; WOOD, 2008). Estudos têm obtido resultados que indicam que os MMEs podem apresentar desempenho igual ou superior aos modelos que os compõem, uma vez que cada MME combina os diferentes aspectos da realidade de um mesmo fenômeno (GUO *et al.*, 2007; XIA *et al.*, 2014).

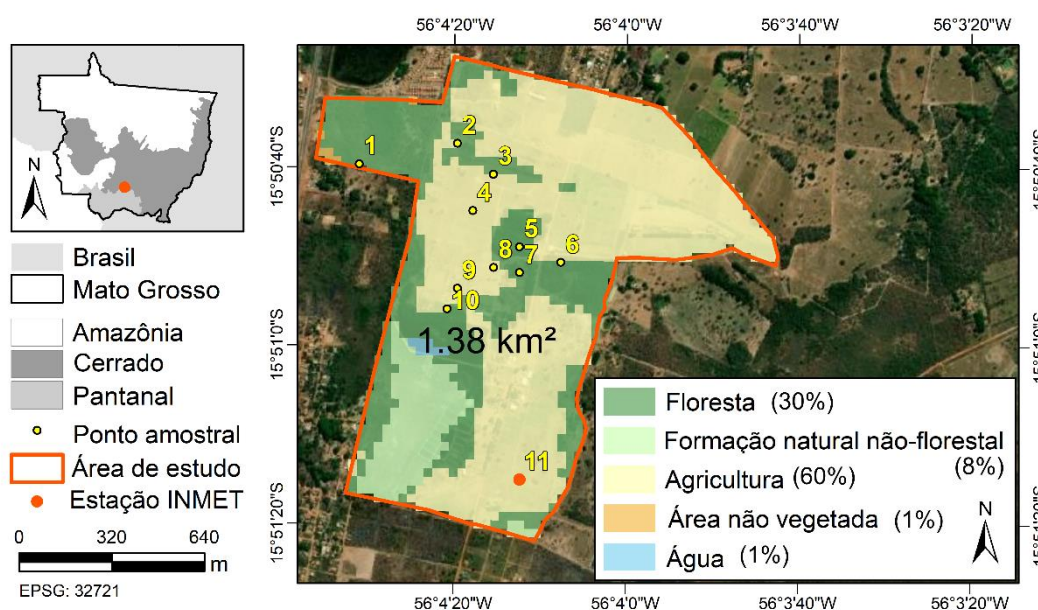
Em geral, a combinação de estimativas por meio de MME envolve dados com diferentes resoluções espaciais. Por isso, métodos como o resampling são utilizados, gerando um produto com resolução espacial igual a estimativa de maior resolução do ensemble (GOOD, 2006). Por esse motivo, a combinação do TOTRAM com os diversos produtos de SM é uma alternativa promissora para o estudo da variabilidade do SM em pequenas áreas, gerando dados que viabilizem políticas sustentáveis de exploração dos recursos naturais do Cerrado (MARACAHIPES-SANTOS *et al.*, 2017). O presente estudo teve como objetivo avaliar as estimativas de SM dos produtos SMOS, SMAP, AMSR2-A, AMSR2-D, ASCAT-A, ASCAT-B, ESA CCI, CLSM-RZ, CLSM-S, NOAH10, NOAH40 e da implementação do TOTRAM, aplicado a dados Landsat 8, além da combinação de desses produtos com o TOTRAM em MMEs, em 11 coberturas do solo entre áreas de vegetação nativa e monoculturas, no Cerrado Mato-Grossense.

## 3.2 Material e métodos

### 3.2.1 Área de estudo

A área de estudo está localizada na Fazenda Experimental da Universidade Federal de Mato Grosso (UFMT) ( $15^{\circ}47'11''$  S  $56^{\circ}04'47''$  W; 180 m acima do nível do mar), no município de Santo Antônio do Leverger, distante 33 km de Cuiabá, Mato Grosso, Brasil (Figura 5). O clima regional é Aw, sendo tropical com inverno seco, com precipitação de  $1335 \text{ mm ano}^{-1}$ . O período chuvoso ocorre de outubro a abril e o período seco de maio a setembro (ALVARES *et al.*, 2013). O solo da região é classificado como PLANOSSOLO HÁPLICO Eutrófico gleissólico, síltico-argiloso (BIUDES *et al.*, 2015). A cobertura do solo da área de estudo é composta por diversas classes, distribuídas entre floresta, formação natural não-florestal, agricultura, área não vegetada e água numa área de  $1,38 \text{ km}^2$  (Figura 5) (SOUZA *et al.*, 2020).

Figura 5 - Localização da Fazenda Experimental da Universidade Federal de Mato Grosso (UFMT), distribuição dos pontos de amostragem, localização da estação meteorológica na área de estudo e classificação da cobertura do solo, no estado de Mato Grosso, Brasil.



Foram selecionados 11 pontos amostrais em diferentes coberturas do solo, nestes pontos foram realizadas amostragens *in situ* e por sensoriamento remoto (Tabela 2). A etapa de coleta dos dados amostrais foi realizada no período de 16 de março de 2015 a 28 de outubro de 2016

Tabela 2 – Identificação e localização dos pontos de amostragem em diferentes coberturas do solo na Fazenda Experimental da Universidade Federal de Mato Grosso, Mato Grosso, Brasil.

Ponto	Símbolo	Cobertura	Latitude	Longitude
1	CS	Cerrado <i>stricto sensu</i>	15° 50' 39,67'' S	56° 4' 31,18'' W
2	TC	Teca	15° 50' 37,30'' S	56° 4' 19,79'' W
3	PT	Pastagem Tanzânia	15° 50' 40,77'' S	56° 4' 15,58'' W
4	PM	Pastagem Mista	15° 50' 44,84'' S	56° 4' 17,96'' W
5	MG	Manga	15° 50' 48,89'' S	56° 4' 12,54'' W
6	CD	Cerradão	15° 50' 50,61'' S	56° 4' 07,73'' W
7	AB	Abacate	15° 50' 51,79'' S	56° 4' 12,52'' W
8	BN	Bananal	15° 50' 51,22'' S	56° 4' 15,53'' W
9	CQ	Coqueiro	15° 50' 53,57'' S	56° 4' 19,72'' W
10	CJ	Caju	15° 50' 55,89'' S	56° 4' 20,91'' W
11	PH	Pastagem humidícola	15° 51' 15,03'' S	56° 4' 12,42'' W

### 3.2.2 Precipitação e conteúdo de água no solo observado

Os dados de precipitação (Ppt) foram medidos na estação meteorológica do Instituto Nacional de Meteorologia (INMET) (OMM: 83364), que se encontra dentro da área de estudo (15° 51' 16,7'' S 56° 04' 14,3'' W), no período de janeiro de 2015 a dezembro de 2016. Foi também obtida a normal climatológica (NC) para os dados de Ppt coletados na estação meteorológica da área de estudo no período de 1981 a 2010.

O conteúdo de água no solo (SM) foi inicialmente observado por meio de um sensor MP406 (ICT International Pty Ltd, Armidale NSW, Austrália). As observações de SM do sensor MP406 foram calibradas a partir de observações realizadas em amostras indeformadas de solo coletadas nos pontos amostrais da área de estudo no mesmo período.

As amostras indeformadas de solo foram coletadas em anéis de amostragem que permitiram calcular a densidade do solo pela razão entre a massa e o volume das amostras. As amostras foram inicialmente pesadas, em seguida secadas em estufa térmica por 24 horas e por fim pesadas novamente, o que permitiu obter a umidade gravimétrica do solo (GSM) da razão entre a diferença de massa do solo úmido (antes da secagem) e do solo seco (após a secagem) e a massa do solo seco. O SM foi calculado pelo produto entre a densidade do solo e a GSM.

### 3.2.3 Dados de satélite

Os dados Landsat 8 foram obtidos na plataforma *Center Science Processing Architecture* (ESPA, [espa.cr.usgs.gov](http://espa.cr.usgs.gov)), que pertence ao Serviço Geológico dos Estados Unidos (USGS). Foram utilizadas somente imagens sem a presença de nuvens sobre a área de estudo. Todas as imagens passaram por correções radiométrica, atmosférica, geométrica sistemática e de precisão, e erro paralaxe pelo modelo digital na plataforma ESPA-USGS.

Foram obtidas estimativas de SM provenientes dos produtos *Soil Moisture and Ocean Salinity* (SMOS; <http://bec.icm.csic.es/bec/>), *Soil Moisture Active Passive* (SMAP; <https://portal.nccs.nasa.gov/datashare/>), *Advanced Microwave Scanning Radiometer 2* (AMSR2; <https://giovanni.gsfc.nasa.gov/giovanni/>), *Advanced Scatterometer* (ASCAT; <https://navigator.eumetsat.int>) (H SAF, 2020), *European Space Agency's Climate Change Initiative for Soil Moisture* (ESA CCI; <https://www.esa-soilmoisture-cci.org/data>) (PREIMESBERGER *et al.*, 2021), *Noah Surface Model* (NOAH; <https://giovanni.gsfc.nasa.gov/giovanni/>) e *Catchment Land Surface Model* (CLSM; <https://giovanni.gsfc.nasa.gov/giovanni/>) (Tabela 3).

Tabela 3 – Soil moisture products of Soil Moisture and Ocean Salinity (SMOS), Soil Moisture Active Passive (SMAP), Advanced Microwave Scanning Radiometer 2 (AMSR2-A and AMSR2-D), Advanced Scatterometer (ASCAT-A and ASCAT-D), European Space Agency's Climate Change Initiative for Soil Moisture (ESA CCI), Catchment Land Surface Model (CLSM-RZ and CLSM-S) e Noah Surface Model (NOAH10 e NOAH40), e suas respectivas resoluções espaciais (RE; km).

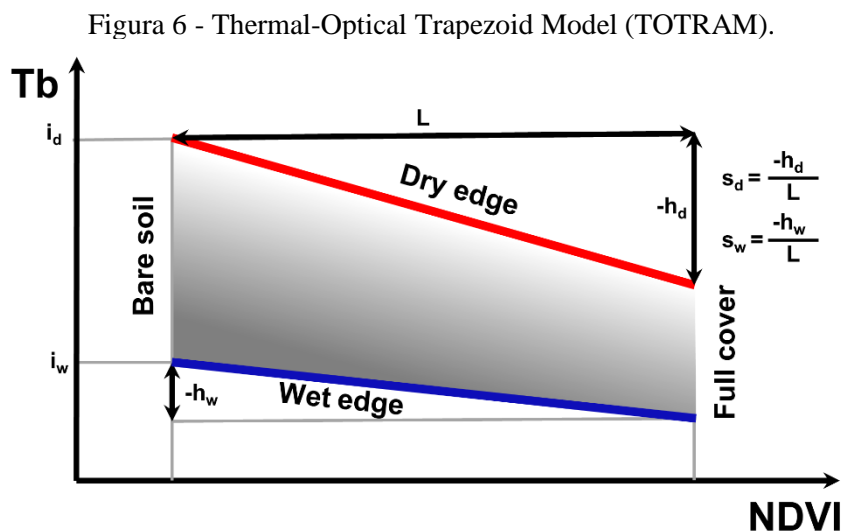
Abreviação	Descrição	RE (km)
SMOS	BEC_SM_SMOS_GLO_L3_20150316T122730_025km_1d_v3.0	25,0
SMAP	GEOS.fp.asm.inst3_2d_smp_Nx.20150316_1500.V01	36,0
AMSR2-A	LPRM_AMSR2_DS_A_SOILM3_001_soil_moisture_c1	10,0
AMSR2-D	LPRM_AMSR2_DS_D_SOILM3_001_soil_moisture_c1	10,0
ASCAT-A	ASCAT Soil Moisture at 12,5 km Swath Grid in NRT - Metop	12,5
ASCAT-B	ASCAT Soil Moisture at 12,5 km Swath Grid in NRT - Metop	12,5
ESA CCI	ESACCI-SOILMOISTURE-L3S-SSMV-COMBINED	28,0
CLSM-RZ	GLDAS_CLSM025_DA1_D_2_2_SoilMoist_RZ_tavg	28,0
CLSM-S	GLDAS_CLSM025_DA1_D_2_2_SoilMoist_S_tavg	28,0
NOAH10	GLDAS_NOAH025_3H_2_1_SoilMoi10_40cm_inst	28,0
NOAH40	GLDAS_NOAH025_3H_2_1_SoilMoi0_10cm_inst	28,0

### 3.2.4 Thermal-optical trapezoidal model

O SM foi estimado pelo *Thermal-Optical Trapezoid Model* (TOTRAM) utilizando os valores do *Normalized Difference Vegetation Index* (NDVI) e da temperatura de brilho ( $T_b$ ; °C) de acordo com a Equação (2) (YANG *et al.*, 2015). O NDVI foi calculado com os valores de refletância espectral da superfície das bandas 5 e 4 do sensor OLI/Landsat 8, de acordo com Ke *et al.* (2015). A  $T_b$  foi obtida diretamente da banda 10 do sensor TIRS/Landsat 8.

$$SM = \frac{(i_d + s_d)NDVI - T_b}{(i_d - i_w) + (s_d - s_w)NDVI} \quad (2)$$

onde,  $i$  e  $s$ ) são os coeficientes linear e angular da regressão linear NDVI- $T_b$ , nas condições de borda seca (d) e borda úmida (w) (Figura 6).



O TOTRAM é construído a partir da hipótese de que existe uma dependência direta e uma forte correlação entre a vegetação, a temperatura da superfície e o SM, de modo que SM é o principal fator que afeta a dinâmica do NDVI e da  $T_b$  (YANG *et al.*, 2015). Além disso, o TOTRAM parte da concepção de um espaço trapezoidal que permite a parametrização do modelo pela relação linear entre NDVI e  $T_b$  (SADEGHI *et al.*, 2017).

### 3.2.5 Parametrização do TOTRAM

Foram utilizados todos os pixels dentro de um buffer de 10 km a partir do perímetro da área de estudo na parametrização do TOTRAM, visando aumentar o número de pixels utilizados na delimitação do espaço trapezoidal NDVI-Tb (YANG *et al.*, 2015). Foram considerados para a parametrização apenas pixels com valores de NDVI entre  $NDVI_{min} = 0,4$  e  $NDVI_{max} = 0,8$ , buscando minimizar a interferência de copos d'água e outliers.

A seleção dos pontos do espaço trapezoidal nas condições extremas de borda seca e borda úmida foi realizada por meio da construção de um algoritmo inédito de varredura dos valores de NDVI e extração dos valores extremos Tb. O objetivo foi proporcionar a implementação do TOTRAM em um número grande de imagens de maneira totalmente automática (Figura 9;Tabela 7). O algoritmo consiste na obtenção do vetor  $NDVI_{par}$  com valores de NDVI distribuídos de forma crescente e regular e dos vetores  $Tb_{max}$  e  $Tb_{min}$  com os valores máximos e mínimos de Tb em cada faixa de valores de NDVI.

O vetor  $NDVI_{par}$  foi criado com os valores de NDVI com intervalos de comprimento  $l_{NDVI} = 0,05$  entre o  $NDVI_{min}$  e o  $NDVI_{max}$ , de acordo com a Equação (3).

$$NDVI_{par} = (NDVI_{min}, NDVI_{min} + nl_{NDVI}) \quad (3)$$

$$n = (1, \dots, \frac{NDVI_{max} - NDVI_{min}}{l_{NDVI}}) \quad (4)$$

Os  $m$  vetores  $Tb_{fil}$  foram criados com os valores de Tb correspondentes aos valores de NDVI em cada longitude ( $lon$ ) e latitude ( $lat$ ), filtrados de acordo com a Equação (5).

$$Tb_{fil}^m = Tb[lon, lat] \text{ if } NDVI_{par}^m \leq NDVI[lon, lat] \leq NDVI_{par}^{m+1} \quad (5)$$

$$m = (1, \dots, \frac{NDVI_{max} - NDVI_{min}}{l_{NDVI}}) \quad (6)$$

em que  $NDVI_{par}^m$  é o m-ésimo termo do vetor  $NDVI_{par}$ .

Os vetores  $Tb_{min}$  e  $Tb_{max}$  foram criados a partir dos valores máximos (seco) e mínimos (úmido) dos vetores  $Tb_{fil}$

$$Tb_{min} = (\min (Tb_{fil}^m)) \quad (7)$$

$$Tb_{max} = (\max (Tb_{fil}^m)) \quad (8)$$

As retas de regressão linear dos cenários de *dry edge* foram calculadas entre  $NDVI_{par}$  e  $Tb_{max}$  e dos cenários de *wet edge* foram calculadas entre  $NDVI_{par}$  e  $Tb_{min}$  (Figura 6).

### 3.2.6 Multi-model ensembles

Os produtos de SM foram classificados e agrupados de acordo com suas propriedades, sendo agrupados por dados monossatélite (Monosat ), multissatélite (Multisat ) e mistos (Multisource ), em seguida as estimativas de SM do TOTRAM foram combinadas em Multi-model ensembles (MME) com os produtos de SM (Tabela 4). O MME “TOTRAM & Monosat” é composto pelas estimativas do TOTRAM e dos produtos SMOS, SMAP, AMSR2-A, AMSR2-D, ASCAT-A e ASCAT-B, que são obtidos a partir do processamento de dados de um satélite (BAUR *et al.*, 2018; BROCCA *et al.*, 2017; DENTE *et al.*, 2012; EL HAJJ *et al.*, 2018; KERR *et al.*, 2012; MISHRA *et al.*, 2018; PARINUSSA *et al.*, 2015; WAGNER *et al.*, 2013; WU *et al.*, 2016). O MME “TOTRAM & Multisat” é composto pelo TOTRAM e pelo produto ESA CCI, que é baseado na fusão de múltiplos sensores de micro-ondas ativos e passivos acoplados em múltiplos satélites (BROCCA *et al.*, 2017; DORIGO *et al.*, 2017; GRUBER *et al.*, 2019; PREIMESBERGER *et al.*, 2021). O MME “TOTRAM & Multisource” é composto pelo TOTRAM e pelos produtos CLSM-RZ, CLSM-S, NOAH10 e NOAH40, que são obtidos por meio do processamento e assimilação de dados de diversas fontes e plataformas em diferentes modelos da superfície (BEAUDOING; RODELL, 2019; LI *et al.*, 2019; RODELL *et al.*, 2004; RUI *et al.*, 2018; SPENNEMANN *et al.*, 2015).

Tabela 4 – Multi-model ensembles (MME) elaborados com estimativas de SM do TOTRAM e dos produtos de SM de dados monossatélite (TOTRAM & Monosat), multissatélite (TOTRAM & Multisat), e mistos (TOTRAM & Multisource), dos produtos gerados a partir de dados de sensores de microondas ativos (TOTRAM & MW Active) e passivos (TOTRAM & MW Passive) e dos produtos que tiveram os melhores desempenhos na validação (TOTRAM & Better).

MME	Produto
TOTRAM & Monosat	TOTRAM, SMOS, SMAP, AMSR2-A, AMSR2-D, ASCAT-A e ASCAT-B
TOTRAM & Multisat	TOTRAM, ESA CCI
TOTRAM & Multisource	TOTRAM, CLSM-RZ, CLSM-S, NOAH10 e NOAH40
TOTRAM & MW Active	TOTRAM, ASCAT-A, ASCAT-B
TOTRAM & MW Passive	TOTRAM, SMOS, SMAP, AMSR2-A e AMSR2-D
TOTRAM & Better	TOTRAM e produtos de SM quando $r$ e $d > 0,75$ ; MAE e RMSE $< 0,15 \text{ m}^3\text{m}^{-3}$

Os produtos de SM gerados a partir de dados de satélites de microonda (MW) foram classificados de acordo com a natureza dos sensores, entre ativos (MW Active) e passivos (MW Passive). Em seguida foram elaborados MMEs entre as estimativas de SM do TOTRAM e dos dois grupos de produtos de satélites MW (Tabela 4). O MME “TOTRAM & MW Active” considera as estimativas do TOTRAM e dos produtos de SM que utilizam dados MW Active, sendo eles ASCAT-A e ASCAT-B (BROCCA *et al.*, 2017; EL HAJJ *et al.*, 2018; WAGNER *et al.*, 2013). O MME “TOTRAM & MW Passive” considera as estimativas do TOTRAM e dos produtos que utilizam dados MW Passive, sendo eles SMOS, SMAP, AMSR2-A e AMSR2-D (BAUR *et al.*, 2018; DENTE *et al.*, 2012; EL HAJJ *et al.*, 2018; JACKSON; SCHMUGGE, 1991; KERR *et al.*, 2012; MISHRA *et al.*, 2018; PARINUSSA *et al.*, 2015; WU *et al.*, 2016). Também foi criado um MME entre as estimativas do TOTRAM e dos produtos de SM que tiveram os melhores desempenhos (Better) na validação de suas estimativas. O MME “TOTRAM & Better” é composto pelos produtos que tiveram o módulo de  $r$  e  $d$  maiores que 0,75 e o MAE e o RMSE menores que  $0,15 \text{ m}^3\text{m}^{-3}$ .

As estimativas de SM em cada MME foram obtidas de médias simples das estimativas dos produtos de SM e do TOTRAM para cada data. Essa metodologia foi

aplicada por ser a mais simples em comparação com outros métodos e por preservar as tendências predominantes entre as estimativas (BHAT *et al.*, 2011; OLSON *et al.*, 2016; YANG *et al.*, 2021).

### 3.2.7 Análise estatística

As médias anuais e sazonais das observações da precipitação (Ppt) foram comparadas com a normal climatológica (NC). O mês de fevereiro de 2015 não foi considerado nas análises por apresentar falhas. A Ppt mensal, o SM observado, o NDVI e a Tb foram avaliados quanto a sua correlação pelo coeficiente de correlação de Spearman ( $r$ ), com nível de significância de 95%.

Os dados foram testados quanto a sua normalidade pelo gráfico Q-Q e pelo teste de Shapiro-Wilk, a 95% de significância (GONZÁLEZ-ESTRADA; COSMES, 2019; R. CORE TEAM, 2022). Em ambos os testes a hipótese de normalidade dos dados foi rejeitada, o que implicou na escolha de métodos não paramétricos nas análises, com o coeficiente de correlação de Spearman (XIAO *et al.*, 2016).

A correlação dos dados estimados com os dados medidos foi avaliada pelo coeficiente de correlação de Spearman, a concordância entre os dados medidos e estimados foi avaliada pelos valores do índice concordância de Willmott ( $d$ ), Equação (9), (WILLMOTT *et al.*, 1985). Os erros de cada estimativa em relação as medidas foi avaliado pelo erro médio absoluto (MAE), Equação (10), e a raiz do erro quadrático médio (RMSE), Equação (11).

Os parâmetros de erro MAE e RMSE expressam o desvio das estimativas em relação ao observado, na unidade da variável. O MAE permite avaliar os erros com menor influência de outliers, sendo mais eficiente quando os erros são uniformes, enquanto o RMSE é mais sensível quando os dados têm valores extremos ou têm distribuição normal (HODSON, 2022). Os parâmetros de erro foram calculados para as estimativas e SM, inicialmente por tipo de coberturas do solo e em seguida para toda a área de estudo.

O  $r$  varia de -1 a 1, em que valores iguais a -1 e a 1 indicando total correlação direta e inversa, respectivamente (XIAO *et al.*, 2016). O  $d$  varia de 0 a 1, com 0 indicando nenhuma concordância entre os dados estimados e os observados enquanto o valor 1 representa total concordância (WILLMOTT *et al.*, 1985).

$$d = 1 - \left[ \frac{\sum (P_i - O_i)^2}{\sum (|P_i - O| + |O_i - O|)^2} \right] \quad (9)$$

$$MAE = \sum_{i=1}^n \frac{|P_i - O_i|}{n} \quad (10)$$

$$RMSE = \sqrt{\frac{\sum (P_i - O_i)^2}{n}} \quad (11)$$

onde,  $P_i$  é o valor estimado,  $O_i$  o valor observado,  $O$  a média do valor observado e  $n$  indica o número total de amostras.

A correlação e a concordância foram classificadas de acordo com a Tabela 5 e, respectivamente. Contudo, esse método foi adotado apenas para facilitar a discussão dos resultados, de modo que os parâmetros também foram discutidos comparando as amostras e verificando os maiores e menores valores (KOZAK, 2009). Esses valores também foram discutidos verificando os efeitos que diferentes metodologias causaram sobre a correlação e concordância, como aumento ou diminuição.

Tabela 5 – Classificação dos valores do coeficiente de correlação de Spearman e dos valores do índice de concordância de Willmott e os respectivos intervalos de classe.

$ r $	Classificação
0,00 a 0,19	Muito fraca
0,20 a 0,39	Fraca
0,40 a 0,69	Moderada
0,70 a 0,89	Forte
0,89 a 1,00	Muito forte
$d$	Classificação
0,00 a 0,20	Muito fraca
0,20 a 0,50	Fraca
0,50 a 0,70	Moderada
0,70 a 1,00	Forte

### 3.3 Resultados e discussão


#### 3.3.1 Variáveis Micrometeorológicas

A precipitação observada (Ppt) teve um padrão sazonal semelhante ao previsto pela normal climatológica (NC), com maior volume de chuvas no período chuvoso e menor no período seco (Tabela 6; Figura 7). No entanto, os acumulados anuais foram diferentes entre os anos, com a precipitação acumulada anual em 2015 menor que em 2016. Em 2015 a Ppt no período chuvoso também foi menor que 2016, mas no período seco esse padrão se inverteu. A Ppt no período chuvoso foi maior que a NC em ambos os anos enquanto no período seco a Ppt foi menor.

Tabela 6 – Valor acumulado sazonal da precipitação (Ppt; mm) observada em 2015 e em 2016 e da normal climatológica (NC) nos períodos seco, chuvoso e anual na Fazenda Experimental da Universidade Federal de Mato Grosso.

Período	Ppt acumulada		
	2015	2016	NC
Anual	916	1468	1213
Chuvoso	814	1392	1095
Seco	102	76	118

Figura 7 – Precipitação (Ppt; mm) mensal observada e normal climatológica (NC) da Ppt (CN) na Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso, em 2015 e 2016. Áreas em cinza representam o período seco e em branco o período chuvoso.



A Ppt acumulada mensal, teve variação semelhante a NC, em que os maiores valores ocorreram nos meses novembro, janeiro e fevereiro e os menores ocorreram nos meses julho e agosto. No período seco alguns meses tiveram Ppt maior que a NC enquanto em outros a NC foi maior. Esse padrão também foi observado no período chuvoso, porém ocorreu de forma mais acentuada, como em fevereiro de 2015 e em janeiro, fevereiro e novembro de 2016 que a Ppt mensal acumulada superou a NC em

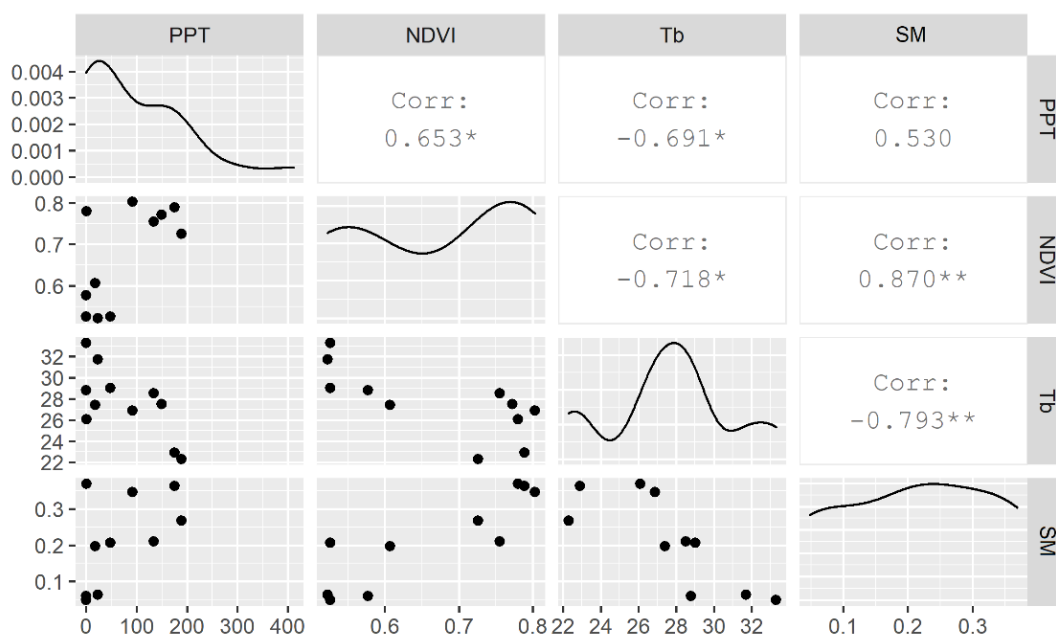
mais de 100 mm. É notável que a Ppt acumulada no período foi maior em 2016 enquanto nesse mesmo ano ocorreram os meses mais chuvosos do período de estudo.

O padrão sazonal identificado neste estudo para a Ppt é semelhante ao apresentado por Biudes et al. (2015) para a mesma região de 2006 a 2010. Os maiores valores de precipitação no período chuvoso estão relacionadas aos eventos causados pelos deslocamentos da Zona de Convergência do Atlântico Sul (ZCAS ) e dos sistemas frontais oriundos da massa polar sul Americana(QUERINO *et al.*, 2017). Essas massas de ar invadem periodicamente o continente sul-americano, levando umidade colhida na superfície quente do mar que aumenta à medida que a massa avança sobre as regiões sul, sudeste, centro-oeste do Brasil, provocando chuvas. Durante o inverno, a partir de junho, os avanços tornam-se mais vigorosos, atingindo o norte de Mato Grosso (BORSATO; MENDONÇA, 2015).

O correlograma apontou para uma correlação positiva moderada entre a Ppt e o *Normalized Difference Vegetation Index* (NDVI), indicando uma dependência da vegetação em relação a sazonalidade da Ppt (Figura 8). A temperatura de brilho (Tb) teve correlação negativa moderada com a Ppt, indicando um padrão de sazonalidade inversa em relação a Ppt. A correlação entre a Ppt e o conteúdo de água no solo (SM) não foi significativa pela análise realizada.

A sazonalidade da Ppt afeta a disponibilidade hídrica no solo, causando variação do volume de água nas camadas mais superficiais, com menores valores no período seco e maiores no período chuvoso (BIUDES *et al.*, 2015; OLIVEIRA *et al.*, 2005; SANTOS *et al.*, 2020). A vegetação é diretamente afetada pela flutuação sazonal da oferta hídrica no solo, variando a intensidade dos processos fisiológicos e a produção de folhas (FAUSTO *et al.*, 2014). Os resultados corroboram com outros estudos realizados na região da área de estudo, em que vêm sendo destacados importante aspectos a respeito da dependência da vegetação no Cerrado em relação a precipitação (BIUDES *et al.*, 2015; FAUSTO *et al.*, 2014).

Figura 8 – Correlograma entre a precipitação acumulada mensal (Ppt; mm), *Normalized Difference Vegetation Index* (NDVI), temperatura de brilho (Tb; °C) e o conteúdo de água no solo (SM;  $m^3m^{-3}$ ) na Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso, em 2015 e 2016. Foi usado o coeficiente de correlação de Spearman com significância de 95%, em que \* indica valor  $p < 0,05$ , \*\* valor  $p < 0,01$  e \*\*\* indica valor  $p < 0,001$ .



A correlação negativa da Ppt com a Tb está relacionada a diferença no balanço de energia da superfície no período seco e no período chuvoso. O aumento da disponibilidade hídrica na camada superficial do solo durante o período chuvoso causa redução do fluxo de calor sensível na superfície (BIUDES *et al.*, 2015). Esse efeito sazonal da Ppt, afeta a temperatura da superfície, de modo que menores valores de fluxo de calor sensível implicam em menos energia para o aquecimento da superfície, conseqüentemente são observados menores valores de Tb (BIUDES *et al.*, 2015; DANELICHEN; BIUDES, 2020).

As correlações entre o NDVI, a Tb e o SM foram fortes, entre 0,72 e 0,87, indicando uma forte dependência entre esses parâmetros (Figura 8). Esse resultado valida os fundamentos teóricos para a construção do TOTRAM e valida a hipótese da existência de uma forte correlação do NDVI e a Tb com o SM. Além disso, a correlação negativa entre o SM e a Tb e positiva entre o SM e o NDVI está de acordo com os resultados a respeito dos efeitos da Ppt e da disponibilidade hídrica no solo sobre a Tb e o NDVI. O aumento do SM favorece o desenvolvimento da vegetação,

aumentando o NDVI enquanto diminui o fluxo de calor sensível e a  $T_b$  (DANELICHEN; BIUDES, 2020; FAUSTO *et al.*, 2014).

A correlação entre o NDVI e a  $T_b$  foi negativa moderada, indicando uma tendência de aumento do NDVI e diminuição da  $T_b$  ao longo da distribuição NDVI- $T_b$  (Figura 8). Esse resultado serve como evidência de que a densidade de biomassa vegetal afeta a termodinâmica da superfície (Figura 8). Além disso, o gráfico da relação entre NDVI e da  $T_b$  apresentou uma distribuição bimodal, que indica a mistura de duas populações, em que uma população se acumula nos valores de NDVI entre 0,5 e 0,6 e a segunda população se acumula entre 0,7 e 0,8 enquanto para ambas as populações os valores de  $T_b$  acumulam em torno de 28°C.

O padrão de distribuição bimodal entre o NDVI e a  $T_b$  ocorre devido a sazonalidade dessas duas variáveis em função do regime de chuvas na região, em que o NDVI no período seco tende a valores menores enquanto a  $T_b$  tende a valores maiores, e o inverso ocorre no período chuvoso. Dessa maneira, se consolida sobre os dados de NDVI e  $T_b$  dois agrupamentos de valores, o primeiro com menores valores de NDVI e maiores de  $T_b$  e o segundo com maiores valores de NDVI e menores de  $T_b$ . A vegetação exerce um papel de termorregulação na superfície, reduzindo a amplitude térmica enquanto aumenta a inércia térmica (MACHADO *et al.*, 2020). Na região sul de Mato Grosso, esse efeito sofre variação principalmente devido as mudanças no comportamento fenológico da maior parte da vegetação, pertencente ao bioma Cerrado, que perde sua folhagem e reduz a taxa de crescimento durante o período seco em resposta ao déficit hídrico no solo (DANELICHEN *et al.*, 2016; FAUSTO *et al.*, 2014).

### 3.3.2 Parametrização do TOTRAM

Na Figura 9 são apresentados os gráficos de dispersão do NDVI por  $T_b$  e na Tabela 7 os valores dos coeficientes linear ( $i$ ) e coeficientes angular ( $s$ ) da retas de regressão nos extremos de solo seco e solo úmido. Pelos gráficos de dispersão é possível notar que nas imagens do período chuvoso há uma maior concentração de pixels próximos ao canto inferior direito. De acordo com o TOTRAM, isso significa que durante o período chuvoso a maior parte da área de estudo tem o solo nas condições de densamente vegetado e úmido (BURDUN *et al.*, 2020; JIANG *et al.*,

2019). Nas imagens do período seco a maioria dos pixels assume menores valores de NDVI e maiores valores de temperatura, se concentrando na região superior esquerda do gráfico. Isso significa que durante o período seco o solo da área de estudo assume em sua maioria a condição de solo pouco vegetado e seco (SADEGHI *et al.*, 2017).

Figura 9 – Gráfico de dispersão entre o *Normalized Difference Vegetation Index* (NDVI) e a temperatura de brilho da superfície (Tb), estimados com imagens Landsat 8, e retas de regressão linear sobre os valores máximos (vermelho) e mínimos (azul) da Tb em função do NDVI, na Fazenda Experimental da Universidade Federal de Mato Grosso, em 2015 e 2016. O gradiente de cores do azul ao vermelho representa a menor (azul) e a maior (vermelho) densidade de pontos.

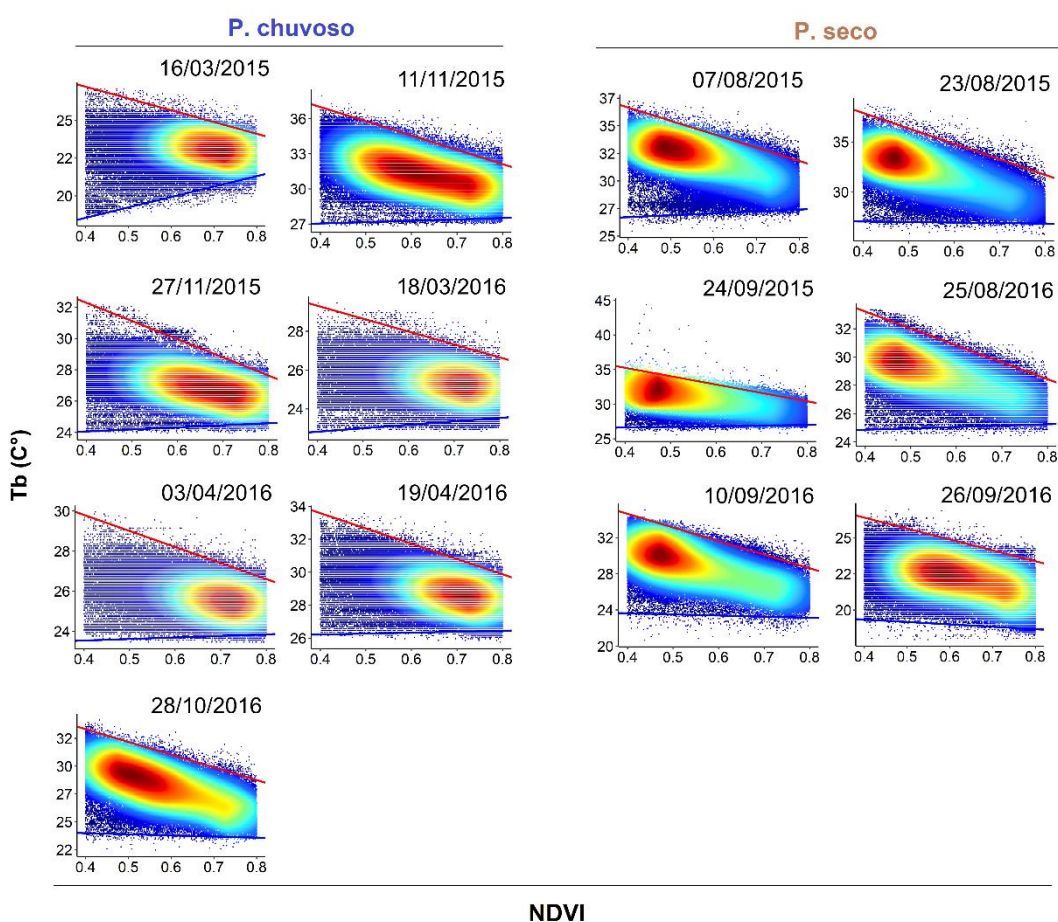


Tabela 7 – Parâmetros das regressões lineares entre o *Normalized Difference Vegetation Index* (NDVI) e a temperatura de brilho (Tb), intercept ( $i$ ; °C) e slope ( $s$ ) nas condições de borda seca (d) e borda úmida (w), estimados com imagens Landsat 8 para a Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso, em 2015 e 2016.

Data	Período	$i_d$	$s_d$	$i_w$	$s_w$
16/03/2015	Chuvoso	30,3	-7,8	15,8	6,9
07/08/2015	Seco	41,5	-12,1	26,0	1,7
23/08/2015	Seco	44,1	-15,5	27,3	-0,5
24/09/2015	Seco	40,1	-12,1	26,2	1,0
11/11/2015	Chuvoso	41,9	-12,2	26,6	1,2
27/11/2015	Chuvoso	36,9	-11,6	23,5	1,3
18/03/2016	Chuvoso	32,0	-6,6	22,1	1,8
03/04/2016	Chuvoso	33,0	-8,0	23,2	0,8
19/04/2016	Chuvoso	37,3	-9,3	26,0	0,6
25/08/2016	Seco	38,0	-11,9	24,5	1,0
10/09/2016	Seco	40,7	-15,1	24,1	-1,2
26/09/2016	Seco	39,4	-15,6	23,6	0,3
28/10/2016	Chuvoso	29,4	-7,5	20,0	-1,7

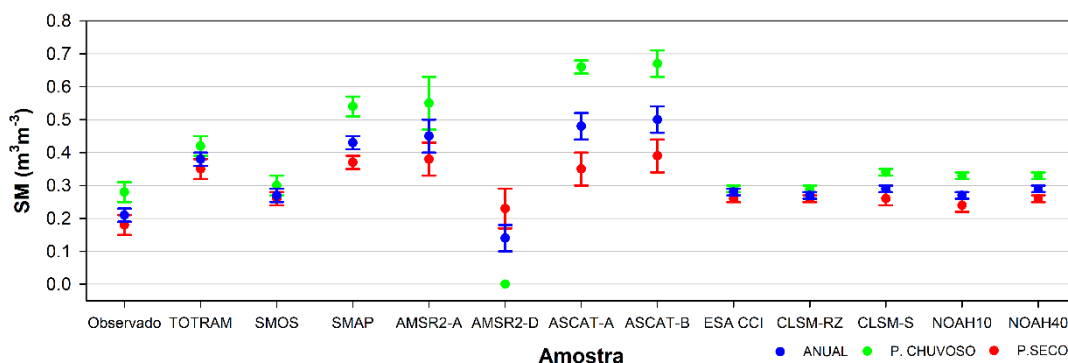
Os valores de coeficiente linear na Tabela 7 foram maiores no período seco para ambas as retas de regressão, o que refletiu numa diferença de aproximadamente 5 °C entre o  $i_d$  e o  $i_w$ . Os coeficientes angulares foram negativos nas retas correspondentes a condição de solo seco e positivo nas retas de solo úmido. Contudo, as retas da borda seca tiveram inclinação mais acentuada enquanto as de solo úmido foram aproximadamente horizontais. Pelo TOTRAM, isso significa que a vegetação tem maior impacto sobre a temperatura da superfície nas regiões com menor disponibilidade hídrica (DAS *et al.*, 2023).

### 3.3.3 Validação do TOTRAM e dos produtos de SM

As estimativas de SM do TOTRAM e dos produtos de SM SMAP, AMSR2-A, ASCAT-A, ASCAT-B, CLSM-S, NOAH10 e NOAH40 tiveram médias anuais e sazonais maiores que as médias do SM observado (Figura 10). As médias e os respectivos intervalos de confiança das estimativas de SM do ESA CCI, CLSM-RZ e SMOS no período chuvoso não indicaram diferença significativa em relação ao SM observado. Os produtos SMOS, ESA CCI, CLSM-S, NOAH10 e NOAH40 foram os


que mais se aproximaram do SM observado, diferindo entre 4% e 24% em relação às respectivas médias anual e sazonal do SM observado.

Figura 10 – Média anual e sazonal, e intervalo de confiança, do conteúdo de água no solo (SM;  $m^3m^{-3}$ ) amostrado in situ (Observado) e estimado pelos produtos TOTRAM, SMOS, SMAP, AMSR2-A, AMSR2-D, ASCAT-A, ASCAT-B, ESA CCI, CLSM-RS, CLSM-S, NOAH-10 e NOAH-40.



O resultado da validação das estimativas de SM está organizado na Figura 11, em que cada gráfico representa os valores de correlação ( $r$ ), concordância ( $d$ ), erro médio absoluto (MAE) e raiz do erro quadrático médio (RMSE), nas diferentes coberturas do solo. A correlação da maioria das estimativas de SM foi positiva em relação ao SM observado, com exceção para os produtos AMSR2-A e AMSR2-D em que a correlação foi negativa. (Figura 11). A correlação foi forte para as estimativas de SM dos produtos SMOS, SMAP, ASCAT-A, ESA CCI, CLSM-RZ, CLSM-S, NOAH10 e NOAH40 em grande parte das coberturas do solo, exceto em PH. O  $d$  teve seus maiores valores para as estimativas de SM dos produtos SMOS, ESA CCI, NOAH10 e NOAH40, acima de 0,65 em todas as coberturas do solo, exceto em PH. De modo geral, as estimativas do TOTRAM e dos produtos de SM tiveram maior correlação e maiores valores de  $d$  em MG enquanto tiveram menor correlação e menores valores de  $d$  em PH.

Figura 11 – Coeficiente de correlação de Spearman ( $r$ ), índice de Willmott ( $d$ ), erro médio absoluto (MAE) e raiz do erro médio quadrado (RMSE) das estimativas do conteúdo de água no solo (SM;  $\text{m}^3\text{m}^{-3}$ ) do modelo TOTRAM e dos produtos SMOS, SMAP, AMSR2-A, AMSR2-D, ASCAT-A, ASCAT-B, ESA CCI, CLSM-RZ, CLSM-S, NOAH10 e NOAH40, calculados em 11 diferentes coberturas de solo (CS, TC, PT, PM, MG, CD, AB, BN, CQ, CJ e PH) e para todas as coberturas (ALL), na Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso, em 2015 e 2016.



O MAE e o RMSE tiveram seus menores valores para as estimativas de SM dos produtos SMOS, CLSM-RZ, CLSM-S, ESA CCI, NOAH10 e NOAH40, abaixo de  $0,15 \text{ m}^3\text{m}^{-3}$  em grande parte das coberturas do solo, exceto para CLSM-RZ e CLSM-S em PH e MG (Figura 11). Em geral, os menores valores de MAE e RMSE das estimativas do TOTRAM e dos produtos de SM foram encontrados na cobertura do solo AB e os maiores foram encontrados na cobertura PH.

Foi identificado um padrão entre os desempenhos das estimativas de SM do TOTRAM e dos produtos de SM, caracterizado por maior desempenho nas estimativas SM a partir de dados mistos (CLSM-RZ, CLSM-S, NOAH10 e NOAH40) seguidas pelas estimativas dos produtos gerados a partir de dados multissatélite (ESA CCI). As estimativas do TOTRAM tiveram desempenho inferior aos produtos de dados mistos

e multissatélite, por outro lado foi superior às estimativas dos produtos gerados a partir de dados monossatélite (SMAP, AMSR2-A, AMSR2-D, ASCAT-A e ASCAT-B). O desempenho das estimativas do produto SMOS foi superior ao modelo TOTRAM, não correspondendo ao padrão identificado para os produtos gerados a partir de dados monossatélite.

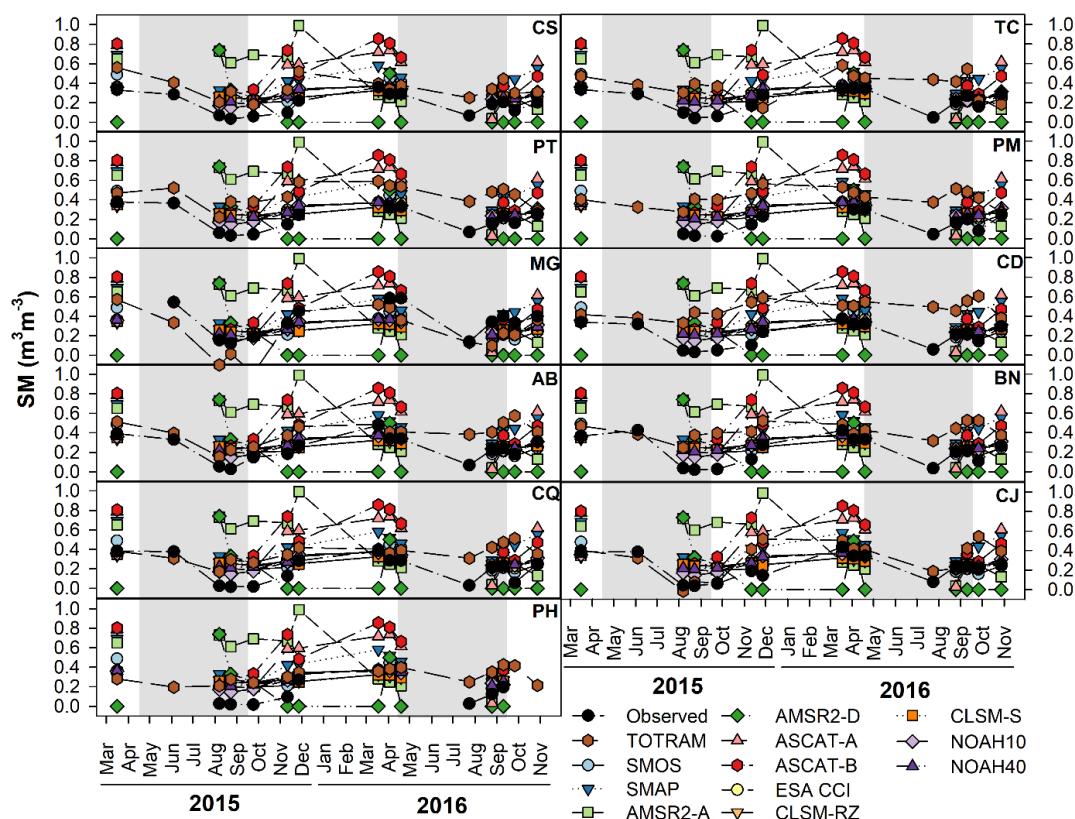
A diferença entre o desempenho dos produtos de SM de dados monossatélite, multissatélite e mistos pode ser explicada principalmente pelo algoritmo e pelo volume de dados de entrada que cada produto utiliza. Os produtos de dados monossatélite utilizam para dados de sensores passivos versões do algoritmo *Land Parameter Retrieval Model* (LPRM) e para os dados de sensores ativos o algoritmo TU Wien (BAUR *et al.*, 2018; BROCCA *et al.*, 2017; DENTE *et al.*, 2012; EL HAJJ *et al.*, 2018; KERR *et al.*, 2012; MISHRA *et al.*, 2018; PARINUSSA *et al.*, 2015; WAGNER *et al.*, 2013; WU *et al.*, 2016). Os produtos multissatélite utilizam algoritmos mais robustos que os monossatélite, combinando modelos físicos e métodos de filtragem e fusão de dados (BROCCA *et al.*, 2017; DORIGO *et al.*, 2017; GRUBER *et al.*, 2019; PREIMESBERGER *et al.*, 2021). Os produtos mistos não utilizam apenas um algoritmo, mas um modelo de superfície que simula a dinâmica de diversas variáveis meteorológica enquanto assimila dados observacionais de diversas fontes e plataformas, de modo que as estimativas são corrigidas com base nessas observações (BEAUDOING; RODELL, 2019; LI *et al.*, 2019; RODELL *et al.*, 2004; RUI *et al.*, 2018; SPENNEMANN *et al.*, 2015). Por esse motivo a metodologia utilizada para obtenção dos dados mistos é a mais robusta e com maior demanda computacional, consequentemente, as estimativas dos produtos multissatélite e mistos apresentam melhor desempenho que os produtos monossatélite.

A análise de erro das estimativas do TOTRAM e dos produtos de SM, considerando todas as coberturas do solo (ALL), resultou em valores de MAE e RMSE maiores aos obtidos na validação em cada cobertura do solo, principalmente nas estimativas do TOTRAM e dos produtos AMSR2-A, ESA CCI, CLSM-RZ, CLSM-S, NOAH10 e NOAH40. O  $r$  nas estimativas do TOTRAM e dos produtos de SM em ALL foi menor que na validação em cada cobertura do solo, com exceção para os produtos AMSR2-A e AMSR2-D. O  $d$  nas estimativas dos produtos SMOS, ESA CCI, CLSM-RZ, CLSM-S, NOAH10 e NOAH40 em ALL foi menor que em cada

cobertura do solo enquanto nas estimativas do TOTRAM e dos produtos SMAP, AMSR2-A, AMSR2-D, ASCAT-A e ASCAT-B o d foi maior que na validação em cada cobertura do solo. Esse resultado indica que o desempenho das estimativas do TOTRAM e dos produtos de SM citados é menor em áreas heterogêneas.

O desempenho das estimativas do TOTRAM foi o que mais variou entre as coberturas do solo, indicando que o desempenho do modelo é mais sensível aos tipos de cobertura solo (Figura 11). O TOTRAM teve maior desempenho nas coberturas do solo que apresentam vegetação de estatura mediana e espaçamento entre as copas de até aproximadamente um metro enquanto teve menor desempenho nos locais com vegetação de pequeno porte e/ou com espaçamento entre copas maior que um metro.

Figura 12 - Séries temporais do conteúdo de água no solo (SM;  $\text{m}^3\text{m}^{-3}$ ) observado e estimado nas 11 coberturas de solo amostradas na Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso. A área sombreada representa o período seco.



As séries temporais do SM observado, o SM TOTRAM e produtos de SM apresentaram o mesmo padrão sazonal nas diferentes coberturas do solo, caracterizado pelo aumento dos valores de SM ao longo do período chuvoso e diminuição ao longo

do período seco (Figura 12). As estimativas de SM do TOTRAM e dos produtos de SM superestimaram o SM em relação ao observado na área de estudo, a exceção das estimativas do produto AMSR2-D.

Como a resolução espacial dos produtos de SM utilizados neste estudo varia entre 10 km e 36 km, os produtos apresentaram os mesmos padrões sazonais de valores de SM para todas as coberturas do solo (Figura 12). O mesmo não aconteceu com SM estimado pelo TOTRAM, que utilizou dados Landsat 8, e por isso tem resolução espacial de 30 m, de modo que os valores de SM foram diferentes em cada cobertura do solo. Desse modo, o desempenho de cada produto de SM em cada cobertura do solo, diferente do TOTRAM, não pode ser relacionado as características desses locais, porque a resolução espacial dos produtos é maior que a extensão da área de estudo.

Os valores dos parâmetros de validação RMSE e  $r$  das estimativas dos produtos de SM estão dentro da mesma faixa encontrada em outros estudos, que também avaliaram os produtos SMOS (PABLOS *et al.*, 2018; SPATAFORA *et al.*, 2020), SMAP (COLLIANDER *et al.*, 2017), CLSM (LI *et al.*, 2019) e NOAH (LIU *et al.*, 2020). O análogo não aconteceu com o TOTRAM que teve desempenho diferente em estudos realizados em outras partes do globo, com menores valores de RMSE e  $r$  (BURDUN *et al.*, 2020; YANG *et al.*, 2015). A variação do desempenho do TOTRAM em diferentes regiões do globo vem sendo discutida por outros estudos, que sugerem que estabelecer uma relação direta entre o SM e o NDVI não é sempre possível, uma vez que o desenvolvimento da vegetação pode ser mais afetado por outros fatores como a radiação solar e a umidade do subsolo (BURDUN *et al.*, 2020). Contudo, neste estudo essa relação se mostrou possível, uma vez que o SM observado e o NDVI apresentaram forte correlação (Figura 8). Dessa forma, relacionar o SM superficial diretamente ao NDVI implicou em considerar que a oferta hídrica nas primeiras camadas do solo afeta diretamente o desenvolvimento da vegetação da região.

Em estimativas do SM pelo modelo TOTRAM, em Uttar, província de Pradesh da Índia, numa área de aproximadamente 5 mil km<sup>2</sup>, o RMSE foi de 0,11 m<sup>3</sup>m<sup>-3</sup> (YADAV *et al.*, 2019). Em *Walnut Gulch* e *Little Washita*, bacias hidrográficas no sul do Arizona e do sudoeste de Oklahoma, com áreas de 148 km<sup>2</sup> e 610 km<sup>2</sup>, respectivamente, foram avaliadas estimativas do SM pelo TOTRAM, em que o RMSE teve valores entre 0,04 m<sup>3</sup>m<sup>-3</sup> e 0,17 m<sup>3</sup>m<sup>-3</sup> (SADEGHI *et al.*, 2017). Esses resultados

indicam que a escala espacial da área de estudo e a diversidade de espécies de plantas também afeta a qualidade das estimativas do TOTRAM (BURDUN *et al.*, 2020).

Dessa forma, a diferença entre o desempenho do TOTRAM neste estudo e nos estudos da literatura é justificada principalmente pela diferença dos tipos de tipos cobertura do solo de cada área de estudo. Outra razão é diferença entre os tamanhos das áreas estudadas pela literatura e a área deste estudo, que é 100 vezes menor que na literatura, de modo que o TOTRAM foi menos afetado pela heterogeneidade da superfície nos estudos da literatura que neste estudo. Além disso, o tipo de solo em cada estudo área também é diferente, de modo que este fator também pode ter influenciado em como a vegetação responde às variações do SM é cada local.

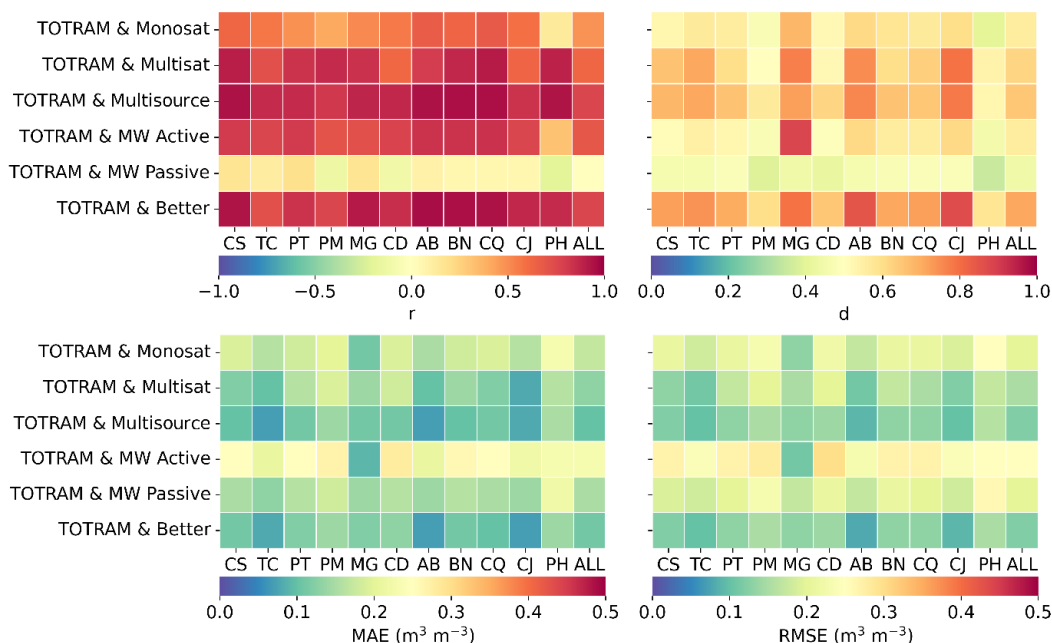
Apesar dos produtos de SM SMOS, SMAP, ASCAT-A, ASCAT-B, ESA CCI, NOAH10, NOAH40, CLSM-RZ e CLSM-S apresentarem forte correlação com o SM medido, suas estimativas não foram capazes de descrever a variabilidade espacial da disponibilidade hídrica do solo em escala microclimática, devido a suas baixas resoluções espaciais (BEAUDOING; RODELL, 2019; PABLOS *et al.*, 2018; XU; FREY, 2021). O TOTRAM, por outro lado, forneceu estimativas de SM com alta resolução espacial, que foram capazes de descrever os gradientes do SM ao longo da área de estudo. Dessa forma, a combinação das estimativas dos produtos de SM e do TOTRAM com médias dos MMEs tem o potencial de fornecer estimativas com forte correlação temporal e alta resolução espacial.

Os produtos de SM que corresponderam aos critérios estabelecidos na Tabela 4 para a composição do MME “TOTRAM & Better” foram SMOS, ESA CCI e NOAH10.

Os MMEs tiveram desempenhos que corroboraram com a validação individual dos produtos de SM (Figura 13). O MME TOTRAM & MW Passive teve o pior desempenho, com menores valores de  $r$  e  $d$  e maiores valores MAE e RMSE enquanto o MME TOTRAM & Better teve o melhor desempenho seguido pelo TOTRAM & Multisource, com  $r$  variando de 0,72 a 0,96,  $d$  variando de 0,53 a 0,87 enquanto o MAE e RMSE variaram de 0,07 a 0,16  $m^3m^{-3}$ . O uso de médias dos MME com SM TOTRAM e os produtos de SM melhorou o desempenho das estimativas de SM, aumentando em média 93% os valores de  $r$  e 23% os valores de  $d$  e diminuindo 28% e 30% os valores de MAE e RMSE, respectivamente.

Os resultados mostram que a correlação e concordância das estimativas TOTRAM aumentou no uso do MME TOTRAM & Better sem prejudicar a descrição da sua variabilidade espacial. Além disso, os erros do MME TOTRAM & Better são menores que os erros do TOTRAM em todas as coberturas do solo, indicando que a variabilidade espacial das estimativas está de acordo com a realidade física da área de estudo no que se refere a umidade do solo.

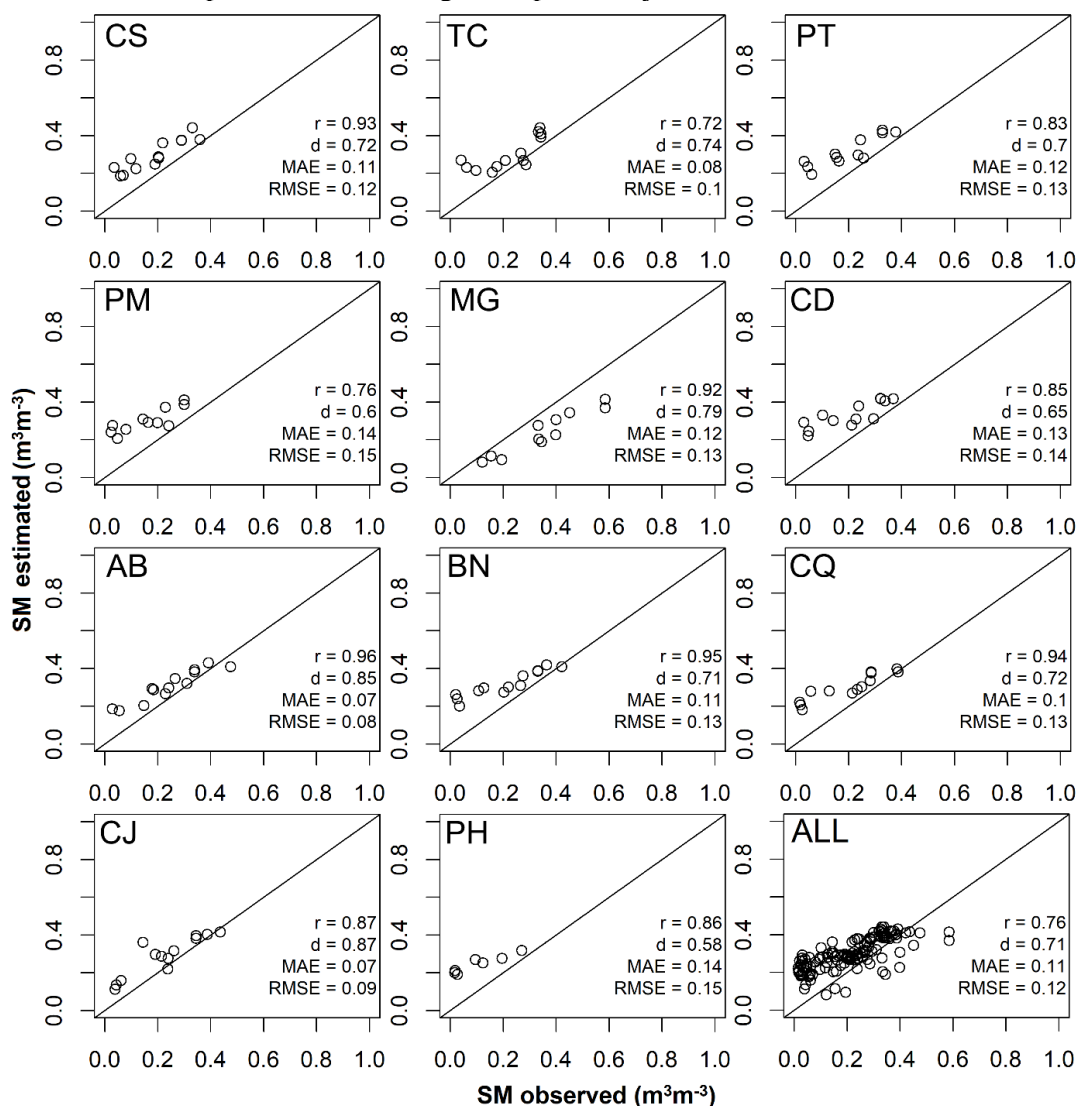
Figura 13 – Coeficiente de correlação de Spearman ( $r$ ), índice de Willmott ( $d$ ), erro médio absoluto (MAE) e raiz do erro quadrático médio (RMSE) das estimativas do conteúdo de água no solo (SM;  $m^3 m^{-3}$ ) dos MMEs TOTRAM & Monosat, TOTRAM & Multisat, TOTRAM & Multisource, TOTRAM & MW Active, TOTRAM & MW Passive and TOTRAM & Better, calculados em 11 diferentes coberturas de solo (CS, TC, PT, PM, MG, CD, AB, BN, CQ, CJ e PH) e para todas as coberturas (ALL), na Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso, em 2015 e 2016.



Os MMEs, em alguns casos, tiveram desempenho superior aos produtos de SM que os integraram. Esse resultado também foi obtido em estudos anteriores, que registraram casos em que os MMEs tiveram desempenho superior a todos os produtos que os integraram (IPCC, 2014; SURCEL *et al.*, 2014). Diversos estudos têm buscado entender em quais condições a incerteza dos MMEs é reduzida, sendo atualmente do consenso desses trabalhos que quanto maior a quantidade de modelos adicionados ao MMEs menor tende a ser a discrepância entre a estimativa e a observação (CHANDLER, 2013; CHRISTIANSEN, 2018; ROUGIER *et al.*, 2013). Porém esse comportamento depende dos modelos que compõem o ensemble, o que levou alguns

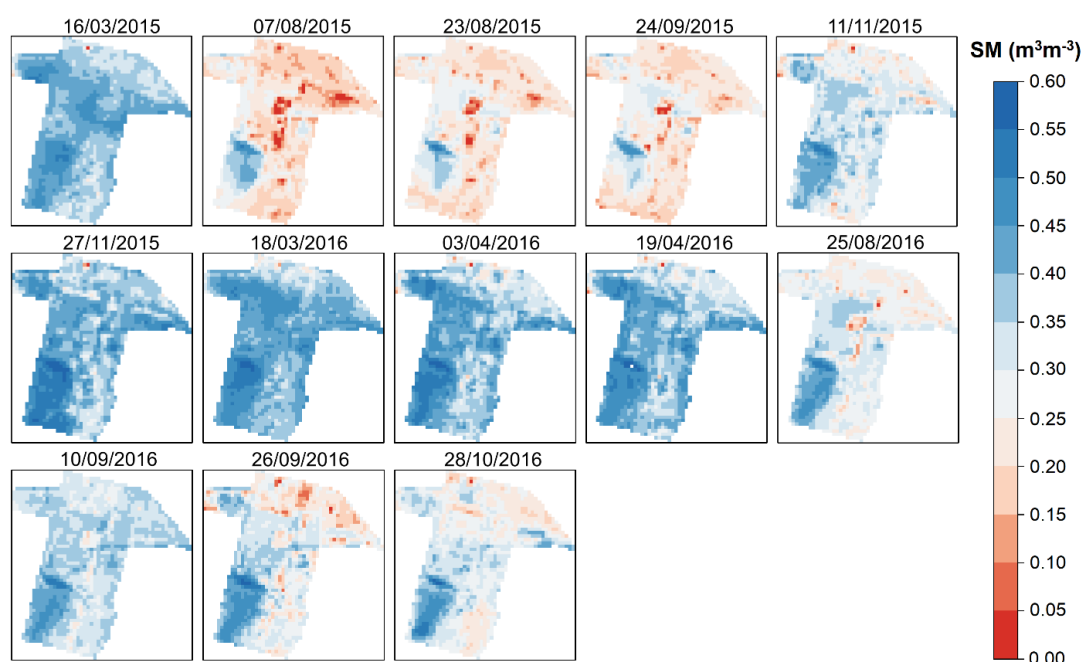
estudos a adicionar métodos bayesianos no cálculo das MMEs (BHAT *et al.*, 2011; OLSON *et al.*, 2016; YANG *et al.*, 2021).

Figura 14 – Estimativas do conteúdo de água no solo (SM;  $m^3m^{-3}$ ) pelo Multi-model Ensemble TOTRAM & Better comparada com medidas em superfície em área de culturas de abacate (AB), banana (BN), caju (CJ), coco (CQ), manga (MG) e em áreas de cerradão (CD), cerrado stricto sensu (CS), pastagem humidícola (PH), pastagem mista (PM), pastagem brachiaria (PT), teca (TC) e para todas as coberturas (ALL) e respectivos valores do coeficiente de correlação de Spearman ( $r$ ), índice de Willmott ( $d$ ), erro médio absoluto (MAE;  $m^3m^{-3}$ ) e raiz do erro quadrático médio (RMSE;  $m^3m^{-3}$ ), na Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso, em 2015 e 2016. A linha diagonal preta determina a região de perfeito ajuste das estimativas.



Uma explicação de natureza geométrica para esse resultado pode ser alcançada, assumindo que as estimativas e as observações de SM apresentam mesma distribuição.(CHRISTIANSEN, 2018). Porém essa explicação viola o cálculo de probabilidade e a hipótese assumida não se mostrar sempre verdadeira (ROUGIER, 2018). Nesse caso, uma abordagem estatística pode ser construída, baseada na permutabilidade dos modelos e suas cocambialidade com o sistema, assumindo que cada produto tem o mesmo vetor de médias e mesma variância, além de cada par de produtos ter a mesma matriz de covariância (ROUGIER *et al.*, 2013). Em todo caso, entender as MMEs não tem se mostrado um processo simples e não há um consenso sobre qual método de combinação diminui mais a incerteza dos modelos (CHANDLER, 2013).

Figura 15 - Estimativas do conteúdo de água no solo (SM) por meio do MME TOTAM & Better na Fazenda Experimental da Universidade Federal de Mato Grosso, em Mato Grosso, em 2015 e 2016.



As imagens de SM estimadas pelo MME TOTRAM & Better tiveram os menores valores no fim do período seco, enquanto os maiores ocorreram durante o período chuvoso (Figura 15). A sazonalidade do SM estimado pelo modelo TOTRAM evidenciaram a dependência da disponibilidade hídrica no solo da região em relação a PPT. Esse resultado corrobora com outros estudos realizados na região do Cerrado

Mato-Grossense, em que devido a sazonalidade da PPT, houve acentuada variação do volume de água nas camadas mais superficiais do solo (BIUDES *et al.*, 2015; FAUSTO *et al.*, 2014).

A distribuição espacial do SM nas imagens estimadas pelo MME TOTRAM & Better teve padrão semelhante à classificação da cobertura do solo da Figura 5. As áreas mais úmidas se concentraram nas coberturas de Floresta e Formação Natural Não Florestal e Água enquanto as mais secas ocorreram em Agricultura (Figura 15). No período chuvoso a maioria das coberturas do solo tiveram valores de SM maiores que  $0,35 \text{ m}^3\text{m}^{-3}$  enquanto no período seco a maioria teve valores de SM abaixo de  $0,35 \text{ m}^3\text{m}^{-3}$ . A área ocupada por Água permaneceu com valores de SM maiores que  $0,35 \text{ m}^3\text{m}^{-3}$  durante todo o período estudado.

Esse padrão está de acordo o que é conhecido a respeito das fitofisionomias do bioma Cerrado, em que áreas mais densas apresentam maior capacidade de manutenção do SM enquanto áreas de vegetação mais rasteira tem menor capacitação acesso e de retenção de água no solo (VOURLITIS *et al.*, 2013). A vegetação do Cerrado é altamente adaptada a variação da oferta hídrica no solo, em geral tendo maior profundidade radicular, o que favorece a obtenção de água em camadas mais profundas, sendo capazes de suportar períodos de estiagem mais longos (GLATZLE *et al.*, 2024). Por outro lado, cultivos não nativos da região são mais afetados pelo baixo teor de água no solo, sobretudo quando a vegetação tem menor profundidade radicular, sendo rapidamente afetada pela redução da oferta hídrica (GLATZLE *et al.*, 2021; OLIVEIRA *et al.*, 2005).

### 3.4 Conclusões

As estimativas de SM a partir de dados mistos (CLSM-RZ, CLSM-S, NOAH10 e NOAH40) tiveram melhor desempenho, seguidas pelas estimativas dos produtos gerados a partir de dados multissatélite (ESA CCI), pelas estimativas do TOTRAM e, por fim, a maioria dos produtos de dados monossatélite (SMAP, AMSR2-A, AMSR2-D, ASCAT-A e ASCAT-B).

O TOTRAM combinado com os produtos SMOS, ESA CCI e NOAH10 em *multi-model ensemble* (MME) foi capaz de gerar estimativas com maior correlação, concordância e menores erros em todas as coberturas do solo.

Os resultados indicam uma base de dados confiável e acessível sobre a disponibilidade hídrica no solo regional, viabilizando novas pesquisas de monitoramento da superfície e políticas de gestão dos recursos naturais.

#### **4. ARTIGO 2: VALIDAÇÃO DE ESTIMATIVAS DA EVAPOTRANSPIRAÇÃO E PRODUTIVIDADE PRIMÁRIA BRUTA PELA COMBINAÇÃO DE DIFERENTES PRODUTOS DE REANÁLISE NOS BIOMAS CERRADO, PANTANAL E AMAZÔNIA**

##### **Resumo**

O estado de Mato Grosso abriga uma ampla diversidade de ecossistemas distribuídos nos biomas Amazônia, Cerrado e Pantanal. A obtenção de dados de evapotranspiração (ET) e produtividade primária bruta (GPP) é fundamental para entender como ocorrem os fluxos de água e carbono e como esses fluxos são afetados pelas mudanças naturais ou antrópicas em cada ecossistema da região. A combinação de produtos de reanálise e de sensoriamento remoto em ensembles têm sido uma alternativa frente a crescente demanda de dados gerada pelos estudos de ecossistemas. No presente artigo, foram avaliadas estimativas individuais e combinadas em médias ensemble (MME) da ET, dos produtos ERA5, FLDAS, PML, SEBAL, SSEBop, TERRA, TERRA-MODIS, e GPP, dos produtos TERRA, AQUA e PML, nos biomas Amazônia, Cerrado e Pantanal em Mato Grosso. A precipitação (Ppt) da missão TRMM foi analisada em termos de sazonalidade e correlação com a ET e o GPP. A Ppt teve maior diferença no Cerrado, até 42% acima da Normal Climatológica e teve maior correlação com a ET e GPP nos biomas Cerrado e Pantanal. As estimativas de ET e GPP tiveram os maiores valores de correlação e concordância e menores erros no Pantanal. Os produtos SSEBop, GLEAM, PML e MME tiveram os melhores desempenhos na análise de erro, concordância e correlação, sendo apontados como as melhores alternativas para estimar a ET ou GPP em Mato Grosso. O uso de MME possibilitou o estudo de áreas de micro e mesoescala, com a maior resolução espacial, o que gerou estimativas com maior detalhamento, sem afetar de tendências predominantes. Os resultados forneceram um conhecimento mais claro de quais dados de ET e GPP são mais adequados para a região, como essas grandezas têm evoluído e quais os cenários futuros em relação a dinâmica dos fluxos de água e carbono no Mato Grosso.

**Palavras-chave:** Ciclo do carbono, Balanço de Energia, Ciclo da água

#### 4.1 Introdução

O estado de Mato Grosso se destaca por abrigar três importantes biomas, Amazônia, Cerrado e Pantanal, e pelo acelerado processo de antropização que vem ocorrendo na região, principalmente a partir da década de 1970 (SOUZA *et al.*, 2020; VOURLITIS *et al.*, 2013). Atualmente existe um grande esforço em pesquisas na região, na tentativa de entender os efeitos da fragmentação das áreas de vegetação nativa sobre diversos parâmetros biofísicos (PRIANTE-FILHO *et al.*, 2004; SABINO; SOUZA, 2023). Contudo, permanecem pouco conhecidos os impactos dessas mudanças na superfície sobre os fluxos de massa, devido principalmente a baixa densidade de pontos amostragem desse tipo de dado, em face a grande extensão do estado de aproximadamente 903 mil km<sup>2</sup> (KUSCHNIG *et al.*, 2021; ULIANA *et al.*, 2024).

Dessa forma, variáveis como evapotranspiração (ET) e a produtividade primária bruta (GPP), que são de suma importância para caracterizar os ecossistemas da região, tem sido estudadas maneira fragmentada e limitada a poucos pontos amostrais (PRIANTE-FILHO *et al.*, 2004; ULIANA *et al.*, 2024). A ET é um importante elemento para o fechamento do balanço hídrico, contribuindo em média com 62% da recuperação de água precipitada, além de ser afetada de maneira distinta pelas as mais diversas variáveis que caracterizam a superfície entre pedológicas, meteorológicas e biofísicas (LATHUILLIÈRE *et al.*, 2012; PINHEIRO *et al.*, 2022). O GPP, apesar da sua importância no controle da dinâmica do carbono, é uma variável pouco coletada, pois demanda um alto custo de equipamentos e infraestrutura tecnicamente exigente.

Atualmente existe uma grande diversidade de produtos, conhecidos como dados de reanálise, que representam uma alternativa promissora como fonte de dados para o estudo de áreas remotas ou com poucos dados de superfície (DE OLIVEIRA *et al.*, 2016; HERBACH *et al.*, 2020; RODELL *et al.*, 2004). Os diversos métodos de recuperação de dados de reanálise foram aprimorados nos últimos anos graças a diversos estudos de validação realizados em várias partes do mundo (DE OLIVEIRA *et al.*, 2016; DUBEY *et al.*, 2022; GELYBÓ *et al.*, 2013; PAREDES *et al.*, 2018; YANG *et al.*, 2017). A implementação desses produtos e sua validação têm mostrado que cada modelo apresenta aspectos parciais da realidade física ao qual se deseja

estudar, de modo que a hipótese é que a combinação desses produtos produziria estimativas mais precisas e com maior confiabilidade (DE OLIVEIRA *et al.*, 2016; FANG *et al.*, 2021; XU; FREY, 2021).

A combinação de estimativas de diversos modelos em ensembles vem sendo adotada como alternativa as atuais limitações enfrentadas nos estudos microclimáticos (GUO *et al.*, 2007; XIA *et al.*, 2014). Os *Multi-model ensembles* (MME) permitem combinar diversos modelos produzindo novas estimativas que, em geral, preservam as tendências e padrões predominantes desses modelos (OLSON *et al.*, 2016). Os métodos de combinação dos MMEs variam entre os estudos, contudo a média tem sido a mais utilizada, pois garante a filtragem das características não concordantes entre os membros do ensemble enquanto reforça os comportamentos da maioria (DUAN *et al.*, 2007; LUO; WOOD, 2008). Estudos têm obtido resultados que indicam que os MMEs podem apresentar desempenho igual ou superior aos modelos que os compõem, uma vez que cada MME combina os diferentes aspectos da realidade de um mesmo fenômeno (GUO *et al.*, 2007; XIA *et al.*, 2014).

O presente estudo teve como objetivo avaliar as estimativas da ET e GPP provenientes de produtos de reanálise e sua combinação em MME, nos biomas Amazônia, Cerrado e Pantanal em Mato Grosso.

## **4.2 Materiais e método**

### *4.2.1 Área de estudo*

A área de estudo compreende o estado de Mato Grosso, Brasil (Figura 16), que possui uma área de aproximadamente 903 mil quilômetros quadrados, ocupada por três biomas, Amazônia, Cerrado e Pantanal. Na Amazônia a vegetação nativa é predominantemente composta por formações florestais enquanto o Cerrado tem a maior parte da sua área coberta formações savânicas e o Pantanal é a região com a maior densidade de áreas alagáveis e formações campestres do estado (Figura 17).

Figura 16 - Distribuição dos pontos de amostragem, biomas e classificação climática no estado de Mato Grosso, Brasil.

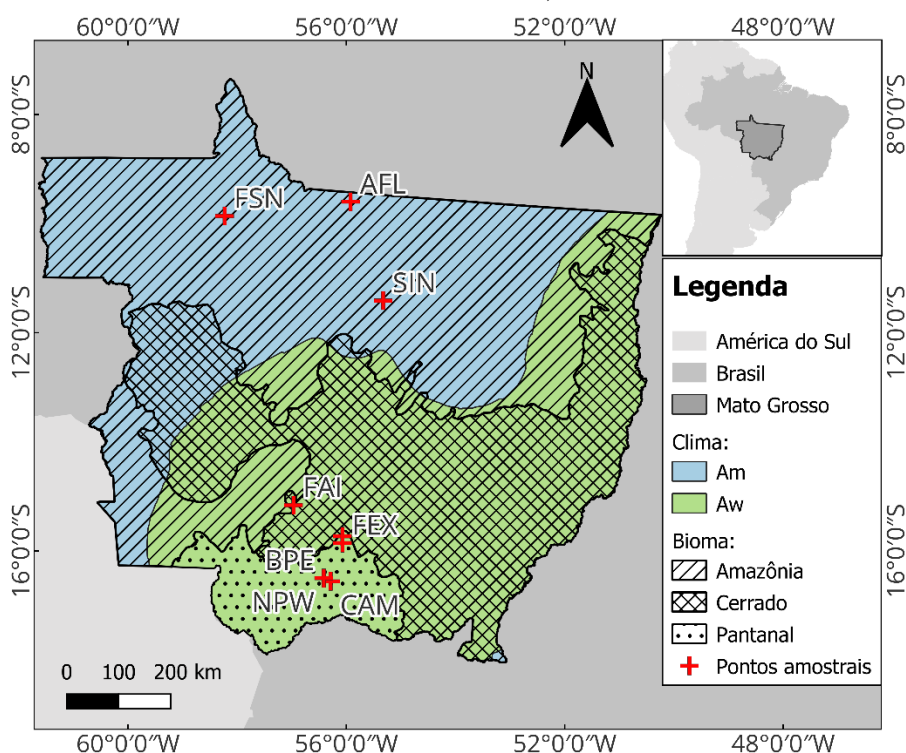
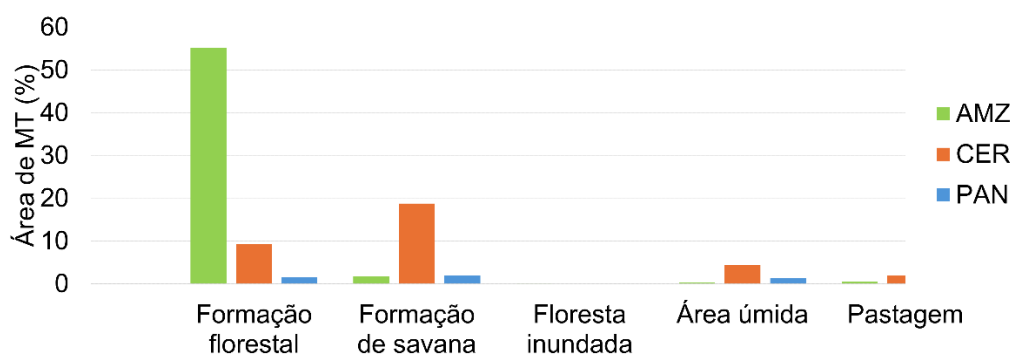


Figura 17 – Cobertura percentual do solo de formação florestal, formação de savana, floresta inundada, área úmida e pastagem dos biomas Amazônia (AMZ), Cerrado (CER) e Pantanal (PAN) em Mato Grosso, Brasil. Adaptado de (SOUZA et al., 2020).



O estado possui duas regiões de classificações climáticas distintas, a primeira com clima Aw (52,8%) (inverno seco) e outra com clima Am (47,2%) (tropical úmido), segundo Köppen (KÖPPEN; GEIGER, 1930), com um gradiente de precipitação positivo no sentido sul-norte, variando de  $1300 \text{ mm ano}^{-1}$  a  $3100 \text{ mm ano}^{-1}$ , além de período chuvoso e período seco bem definidos (ALVARES *et al.*, 2013; BIUDES *et al.*, 2022).

Foram coletados dados em nove pontos amostrais, distribuídos nos três biomas do estado de Mato Grosso, Cerrado, Pantanal e Amazônia, três na Amazônia, três no Cerrado e três no Pantanal (Figura 16; Tabela 8). O ponto amostral aqui referido como AFL situa-se no bioma amazônico foi em uma floresta ombrófila densa e perenifólia localizada a 39 km a nordeste da cidade de Alta Floresta, no sul da Bacia Amazônica (9°36'2,83"S, 55°55'22,22"W). A vegetação nesse local é composta por *Tetragastris altissima* (22%), *Celtis schippii* (17%) e *Pseudolmedia sp* (6%), com altura média de dossel de 30 a 35 m, mas com algumas árvores emergentes atingindo até 45 m de altura. A temperatura média anual de 30 anos na região de Alta Floresta é de 25,7 °C, e a precipitação é de aproximadamente 2230 mm ano<sup>-1</sup>, com uma estação seca de junho a setembro. O solo é classificado como Argissolo Vermelho-Amarelo (pH = 4,5), com baixos teores de fósforo, cátions extraíveis e matéria orgânica.

O ponto amostral aqui denominado de SIN, também no bioma amazônico, é uma floresta de transição Amazônia-Cerrado na região norte do estado de Mato Grosso, a 50 km da cidade de Sinop (11°24'45"S, 55°19'30"W, 423 m acima do mar). A vegetação do SIN é composta principalmente por várias espécies que incluem *Brosimum lactescens*, *Qualea paraensis* e *Tovomitia schomburkii*. A altura do dossel sobre o SIN varia entre 25 e 28 m, e o Índice de Área Foliar (IAF) varia entre 4,8 m<sup>2</sup> m<sup>-2</sup> durante a estação chuvosa e 4,2 m<sup>2</sup> m<sup>-2</sup> durante a estação seca. O solo é um Neossolo (Neossolo Quartzoso), caracterizado por aproximadamente 90% de areia, baixo pH (4,2) e baixa fertilidade. A temperatura média do ar na região é de cerca de 24,7 °C, com uma precipitação anual de aproximadamente 2000 mm ano<sup>-1</sup> que cai durante a estação chuvosa seguida por uma estação seca de 5 meses (maio-setembro).

O terceiro ponto amostral no bioma amazônico, aqui referido como FSN, é uma pastagem localizada na Fazenda São Nicolau perto de Cotriguaçu (9°51'43,8"S, 58°13'48,6"W). O local do FSN é dominado por uma pastagem não nativa de *Brachiaria brizantha*, e o solo foi classificado como Latossolo Vermelho (BIUDES *et al.*, 2022; PRIANTE-FILHO *et al.*, 2004).

O ponto amostral no bioma Cerrado, aqui denominado FAI, situa-se em área de Cerrado *stricto sensu* e localiza-se na Fazenda Arco-Íris, a 20 km da Barra do Bugres (15°10'38,88"S, 56°58'3,41"W) (Figura 1). O solo da região é o Neossolo, com

altas taxas de infiltração de água, mas com reduzida capacidade de retenção de água (BIUDES *et al.*, 2022; FAUSTO *et al.*, 2014).

O segundo ponto amostral no Cerrado, aqui denominado FMI, situa-se na Fazenda Miranda, 15 km ao sul de Cuiabá (15°43'53,66"S, 56°04'18,81"W) (Figura 1). A vegetação do FMI é caracterizada por uma floresta mista-campo (localmente conhecida como campo sujo) dominada por gramíneas nativas e não nativas, juntamente com as espécies arbóreas semidecíduas *Curatella americana* L. e *Diospyros hispida* A. DC. O solo da região é Latossolo Vermelho distrófico, com altas taxas de infiltração de água, mas com reduzida capacidade de retenção de água. A temperatura média mensal do ar varia de 18 °C em junho-julho a um máximo de 29 °C em outubro, e a precipitação média anual é de 1372 mm ano<sup>-1</sup>, seguida de uma estação seca de maio a setembro (BIUDES *et al.*, 2022; MACHADO *et al.*, 2015; VOURLITIS *et al.*, 2013).

O terceiro ponto amostral no Cerrado, aqui denominado FEX, situa-se em um campo não nativo localizado na Fazenda Experimento, 33 km ao sul de Cuiabá (15°51'15,23"S, 56°04'13,50"W). A pastagem na FEX é dominada pela *Brachiaria humidicola* não-nativa. O tipo de solo regional em ambos os locais de pesquisa é o Latossolo Vermelho distrófico, com altas taxas de infiltração de água, mas com capacidade limitada de retenção de água (BIUDES *et al.*, 2015, 2022).

Os pontos amostrais aqui denominados CAM, BPE e NPW estão em uma região hiper sazonalmente alagada no Pantanal (Figura 1). O ponto amostral aqui referido como CAM situa-se numa área de vegetação monodominante de *Vochysia divergens* Pohl, conhecida localmente como "Cambarazal", com uma altura de dossel que varia entre 28 e 30 m, com um IAF médio de 3,5 m<sup>2</sup> m<sup>-2</sup> localizado na Reserva Particular do Patrimônio Nacional (RPPN) SESC Pantanal, distante 107 km de Cuiabá (16°33'19,11"S, 56°17'11,49"W) (BIUDES *et al.*, 2015; VOURLITIS *et al.*, 2011). O ponto BPE e NPW estão localizados em uma área experimental denominado Baía das Pedras, a 105 km a sudoeste de Cuiabá (16°29'53,52"S, 56°24'46,23"W). A vegetação é predominantemente do tipo *Combretum lanceolatum* Pohl, conhecida localmente como "Pombeiral", que é um arbusto de grande porte de até 3 m de altura que cresce em matas muito densas em todo o Pantanal (MACHADO *et al.*, 2016; MORAES *et al.*, 2022). O solo é classificado como GLEISSOLO HÁPLICO Ta Distrófico. A

topografia da região é caracterizada por planícies alagáveis durante o período chuvoso, com altitude média de 120 m acima do nível do mar. Essa região apresenta precipitação de 1400 mm ano<sup>-1</sup>, com um período chuvoso ocorrendo de outubro a abril e um período seco de maio a setembro e temperatura média anual de 26,1 °C (DUARTE *et al.*, 2019).

Tabela 8 – Pontos amostrais nos biomas Amazônia, Cerrado e Pantanal, suas localizações, descrição dos seus ecossistemas e o período de amostragem de cada série de dados, em Mato Grosso.

Bioma	Símbolo	Descrição	Ecossistema	Período de amostragem
Amazônia	AFL	Alta Floresta	Floresta ombrófila densa e perenifólia	2002–2003
	SIN	Sinop	Floresta de transição Amazônia-Cerrado	2001–2008
	FSN	Fazenda São Nicolau	Pastagem não-nativa <i>Brachiaria brizantha</i>	2002–2003
Cerrado	FAI	Fazenda Arco-íris	Cerrado <i>Stricto Sensu</i>	2019–2020
	FMI	Fazenda Miranda	Floresta mista-campo (Campo sujo)	2009–2013
	FEX	Fazenda Experimental	Pastagem não-nativa <i>Brachiaria humidicola</i>	2006–2009
Pantanal	CAM	Cambarazal	Área sazonalmente alagável composta por <i>Vochysia divergens</i> Pohl (Cambará)	2006–2009
	BPE	Baía das Pedras	Área sazonalmente alagável composta por <i>Combretum lanceolatum</i> Pohl (Pombeiro)	2010–2015
	NPW	Eddy Covariance Pantanal	Área sazonalmente alagável composta por <i>Combretum lanceolatum</i> Pohl (Pombeiro)	2013-2017

#### 4.2.2 Dados de superfície

A evapotranspiração nos pontos amostrais AFL, FAI, FEX e CAM foi calculada pelo método da razão de Bowen, com dados coletados em superfície de acordo com a Tabela 9 (BIUDES *et al.*, 2015). A evapotranspiração nos pontos amostrais SIN, FSN, FMI, BPE e NPW foi obtida por um sistema Eddy covariance

(Anemômetro sônico tridimensional CSAT3 - Campbell Scientific, Logan, UT, USA; LI-7500A - LICOR Inc., Lincoln, NE, USA) instalado a 20 m acima do solo.

Os dados de GPP foram obtidos com um sistema de Eddy Covariance que foi montado nas torres de pesquisa de Sinop (SIN), Fazenda São Nicolau (FSN), Fazenda Miranda (FMI) e Pantanal (NPW) (Tabela 9). O sistema de Eddy Covariance consistia em um anemômetro sônico 3D usado para medir as componentes tridimensionais ortogonais de velocidade ( $u_x$ ,  $u_y$ ,  $u_z$ ) e determinar flutuações de temperatura sônica de alta frequência, bem como dois analisadores de gás infravermelho para medir as concentrações de CO<sub>2</sub>. Os dados foram coletados de 2001 a 2017.

Os dados brutos de Eddy covariância foram processados usando o software EddyPro® (v.6.2.0) (LI-COR Biosciences, Lincoln, Nebraska, EUA) em intervalos de 30 minutos. O software faz correções nas flutuações de densidade do ar Webb Pearman-Leuning (DETTO e KATUL, 2007; WEBB, PEARMAN, e LEUNING, 1980), correções espectrais (MONCRIEFF, CLEMENT, FINNIGAN, e MEYERS, 2004), correção de umidade da temperatura sônica (VAN DIJK, MOENE, e BRUIN, 2004), e a correção da resposta de frequência incorporada (LEE, MASSMAN, e LAW, 2004; MASSMAN, 2000). Em seguida os dados foram convertidos para a unidade gC m<sup>-2</sup> dia<sup>-1</sup>.

Tabela 9 – Descrição dos equipamentos utilizados para medir as variáveis radiação solar global (R<sub>g</sub>), saldo de radiação (R<sub>n</sub>), temperatura do ar (T<sub>a</sub>), umidade relativa do ar (RH), fluxo de calor no solo (G), e suas respectivas alturas de instalação em cada ponto amostral. As descrições de cada abreviação estão na Tabela 8.

Variável	Descrição do equipamento	Altura de instalação (m)							
		AFL	SIN	FSNFAI	FMI	FEX	CAM	BPE	NPW
R <sub>g</sub>	LI200X, LI-COR, Lincoln, NE, USA	50	42		5	2	33	20	
R <sub>n</sub>	NRLITE, Kipp & Zonen, Delft, Netherlands	50	42		5	2	33	20	
T <sub>a</sub> /RH	HMP-45AC, Vaisala Inc., Woburn, MA, USA	45/51	39/45		5/18	0,5/1,833	37/22	31	
G	HFP01, Hukseflux BV, Delft, The Netherlands	-0,01	-0,01		-0,01	-0,01	-0,01	-0,01	
GPP	LI-COR Biosciences, Lincoln, Nebraska, EUA				18				20

Foram obtidos dados da normal climatológica da precipitação acumulada mensal (P<sub>pt</sub>), de 1981 a 2010, de três estações meteorológicas do Instituto Nacional de Meteorologia (INMET), localizadas nos municípios de Matupá (Estação: Matupá; OMM: 83214; Lat: 10°11'24,00"S; Lon: 54°57'0,00"W), Santo Antônio do Leveger (Estação: Padre Ricardo Remetter; OMM: 83364; Lat: 15°51'15,23"S; Lon: 56°

4'13,50"W) e Cáceres (Estação: Cáceres; OMM: 83405; Lat: 16° 3'0.00"S; Lon: 57°40'48.00"W), localizadas nos biomas Amazônia, Cerrado e Pantanal, respectivamente.

#### 4.2.3 Dados de reanálise

Os produtos de evapotranspiração ERA5, FLDAS, PML, SEBAL, SSEBop, TERRA, TERRA-MODIS foram obtidos da plataforma *Google Earth Engine*. Foram selecionados apenas os dados sobre a área de estudo no período dos dados coletados em superfície (MUÑOZ-SABATER *et al.*, 2021; PELOSI *et al.*, 2020).

O ERA5 é um produto desenvolvido e implementado pelo *European Centre for Medium-Range Weather Forecasts* (ECMWF) dentro do *Copernicus Climate Change Service* (C3S), sendo a quinta geração de reanálise desde 1979 (HERSBACH *et al.*, 2020). O ERA5 foi lançado em 2017 com um sistema mais avançado de assimilação e esquemas de parametrização em relação às gerações anteriores, além de uma maior resolução espaço-temporal e uma quantidade maior de parâmetros (mais de 240 parâmetros) (JIANG *et al.*, 2021). Os sistemas FLDAS são instâncias personalizadas do Sistema de Informação Terrestre da NASA (LIS) que derivam em três sistemas de modelagem, FLDAS-Global (MCNALLY *et al.*, 2017), FLDAS-Ásia Central (MCNALLY *et al.*, 2022) e FLDAS-Forecast (HAZRA *et al.*, 2023). Os dados FLDAS possuem um período de cobertura de 1981 até o presente, sendo aplicados principalmente em estudos de monitoramento de seca agrícola e caracterização de seca (KHAKI *et al.*, 2018; MCNALLY *et al.*, 2017). O modelo Penman-Monteith-Leuning (PML) foi desenvolvido a partir da proposta de estimativa da condutância superficial, que descreve a condutância dossel-solo ao fluxo de água (LEUNING *et al.*, 2008). O PML foi proposto em 2008 e desde então tem passado por modificações, chegando a versão PML-V2, em que suas estimativas são baseadas em dados MODIS (ZHANG *et al.*, 2019). O *Surface Energy Balance Algorithm for Land* (SEBAL) calcula os fluxos de calor latente pelo método do balanço de energia residual, em que a parametrização ocorre por um procedimento numérico iterativo e baseado em *feedback*, deduzindo os fluxos de radiação, calor e evapotranspiração (ALLEN *et al.*, 2002; ANGELINI *et al.*, 2021).

O SEBAL utiliza dados espacialmente distribuídos, obtidos de sensores orbitais multiespectrais, se mostrando um modelo eficaz na estimativa da ET em ambientes heterogêneos ou em áreas agrícolas (LAIPELT *et al.*, 2021; MA *et al.*, 2023). O SSEBop utiliza uma abordagem de resolução de parte do componentes do balanço de energia com foco na obtenção da ET (YIN *et al.*, 2020). O SSEBop foi proposto em 2013 com o objetivo de estimar a ET a partir de um número menor de entradas meteorológicas e dados de sensoriamento remoto, facilitando o monitoramento da ET em períodos mais longos e em mais locais (SENAY *et al.*, 2022; SHARMA; TARE, 2018). O algoritmo MOD16 calcula a ET usando uma equação de Penman-Monteith modificada somando a evaporação do solo úmido, a evaporação da copa úmida das plantas e a transpiração das plantas (HE *et al.*, 2019). O produto MOD16A2 é resultado de uma série de aprimoramentos do modelo desde 2007, resultando na versão 6 que estima a ET a cada 8 dias e com cobertura temporal de 2000 até o presente (DEGANNO *et al.*, 2021).

Tabela 10 – Descrição dos produtos das estimativas das variáveis evapotranspiração (ET) e produtividade primária bruta (GPP) e suas respectivas resoluções espaciais e referências.

Produto	Variável	Descrição	Resolução espacial	Referência
ERA5	ET	ECMWF/ERA5_LAND/MONTHLY_AG GR	11 km	Muñoz, 2019
FLDAS	ET	NASA/FLDAS/NOAH01/C/GL/M/V001	11 km	McNally, 2018
PML	ET	CAS/IGSNRR/PML/V2_v017	0,5 km	Zhang et al., 2016
SEBAL	ET	geeSEBAL - Earth Engine Apps	0,03 km	Laipelt et al., 2021
SSEBop	ET	SSEBopBR V2 - Earth Engine Apps	0,03 km	Dias Lopes et al., 2019
MODIS	ET	MODIS/061/MOD16A2	0,5 km	(RUNNING et al., 2017)
GLEAM	ET	GLEAM v3	27 km	(MARTENS et al., 2017)
Terra Climate	ET	IDAHO_EPSCOR/TERRACLIMATE	4,6 km	(ABATZOGLOU et al., 2018)
MODIS- TERRA	GPP	MODIS/061/MOD17A2H	0,5 km	(RANJAN; GORAI, 2022)
MODIS- AQUA	GPP	MODIS/061/MYD17A2H	0,5 km	(RUNNING et al., 2015)
PML	GPP	CAS/IGSNRR/PML/V2_v017	0,5 km	(ZHANG et al., 2019)

Os produtos MOD17A2H e MYD17A2H estimam a produtividade primária bruta (GPP) a partir de duas fontes de dados de entrada: dados meteorológicos, obtidos dos dados de reanálise do *Global Modeling and Assimilation Office* (GMAO), e dados de fração de radiação fotossinteticamente ativa absorvida () fornecidos pelos produtos MOD15A2H e MYD15A2H, respectivamente (WANG *et al.*, 2017; ZHANG *et al.*, 2023). O algoritmo GPP do MODIS é um modelo semiempírico que parte de uma abordagem da eficiência de uso da luz (LUE), em que o GPP é um produto da radiação fotossinteticamente ativa absorvida (YANG *et al.*, 2023; ZHANG *et al.*, 2019, 2023).

Os dados de precipitação (Ppt) foram obtidos a partir das estimativas do produto 3B432 V7 do satélite *Tropical Rainfall Measurement Mission* (TRMM) baixados do Plataforma Giovanni da *National Aeronautics and Space Administration* (NASA) (<https://giovanni.gsfc.nasa.gov/giovanni/>, acesso em 15/08/2023) (JUNIOR *et al.*, 2021).

#### 4.2.4 Método da razão de Bowen

A estimativa da evapotranspiração pelo método da razão de Bowen (BRM), proposto em 1926, apresenta vantagem, pois apresenta uma abordagem física clara, de poucos parâmetros e um processamento que demanda baixo custo computacional. Além disso, já tem sido validado em diversos locais, tendo fornecido valores precisos e confiáveis (BIUDES *et al.*, 2015; RODRIGUES *et al.*, 2013).

A estimativa da ET pelo método BRM seguiu as orientações e modificações descritas por Perez *et al.* (1999), de acordo com a Equação (12)

$$ET = \left( \frac{LE}{\lambda} \right) \quad (12)$$

onde LE é o fluxo de calor latente ( $\text{W m}^{-2}$ ), calculado pela Equação (13), e  $\lambda$  é o calor latente de vaporização, calculado pela Equação (14).

$$LE = \frac{Rn - G - \Delta S}{1 + \beta} \quad (13)$$

$$\lambda = 1,919 \times 10^{-6} \left( \frac{T}{T - 33,91} \right)^2 \quad (14)$$

onde  $R_n$  é saldo de radiação ( $\text{W m}^{-2}$ ),  $G$  é o fluxo de calor no solo ( $\text{W m}^{-2}$ ),  $\Delta S$  é o estoque de calor no espaço aéreo do dossel e na biomassa ( $\text{W m}^{-2}$ ) e  $T$  é a temperatura média do ar (K). O  $\Delta S$  foi calculado usando a parametrização proposta por Moore and Fisch (1986), sendo considerado apenas em AFL, SIN, FSN e CAM e desprezado em FAI, FMI, FEX e BPE, devido a baixa densidade de biomassa nesses pontos (BIUDES *et al.*, 2022). A razão de Bowen,  $\beta$ , foi calculada de acordo com a Equação (15)

$$\lambda = \left( \frac{C_p}{0,622\lambda} \right) \left( \frac{\Delta T}{\Delta e} \right) \quad (15)$$

onde  $C_p$  é calor específico a pressão constante ( $1,00467 \text{ J g}^{-1} \text{ K}^{-1}$ ), 0,622 é a proporção entre as massas moleculares da água e do ar, e  $\Delta T$  e  $\Delta e$  são as diferenças de temperatura (K) e pressão de vapor de água (kPa) entre medições em alturas diferentes, respectivamente.

Alguns detalhes da estimativa da ET pelo método BRM, aqui suprimidos podem ser obtidos em Biudes *et al.* (2022).

#### 4.2.5 Multi-model ensembles

As estimativas dos produtos de ET e GPP foram agrupadas em ensembles (MME) com o objetivo de obter novas estimativas a partir da combinação dos produtos de cada variável. Foram utilizados todos os produtos disponíveis no repositório da plataforma Google Earth Engine e com sobreposição temporal dos dados. Cada produto foi redimensionado para a mesma resolução espacial do produto de melhor resolução e em seguida foram calculas médias das estimativas e obtido o produto ENSEMBLE. Esses procedimentos foram realizados utilizando o pacote ‘raster’ no software R (R. CORE TEAM, 2022).

Essa metodologia foi aplicada por ser a mais simples em comparação com outros métodos e por preservar as tendencias predominantes entre de cada produto (BHAT *et al.*, 2011; OLSON *et al.*, 2016; YANG *et al.*, 2021). O ensemble da ET é

composto pelas estimativas dos produtos ERA5, FLDAS, PML, SEBAL, SSEBop e MODIS. O ensemble do GPP é composto pelos produtos TERRA, AQUA e PML.

#### 4.2.6 Análise estatística

Os dados foram testados quanto a sua normalidade pelo gráfico Q-Q e pelo teste de Shapiro-Wilk, a 95% de significância (GONZÁLEZ-ESTRADA; COSMES, 2019; R. CORE TEAM, 2022). Em ambos os testes a hipótese de normalidade dos dados foi rejeitada, o que implicou na escolha de métodos não paramétricos nas análises, com o coeficiente de correlação de Spearman (XIAO *et al.*, 2016).

As médias anuais e sazonais da Ppt foram comparadas com a normal climatológica (NC; 1981 a 2010) para identificar os períodos de chuva abaixo ou acima do esperado. Foi calculada a correlação das estimativas mensais da ET e do GPP com a Ppt, pelo coeficiente de correlação de Spearman ( $r$ ), com nível de significância de 95%, com o objetivo de entender como o regime de chuvas na região afeta o fluxo de vapor e a assimilação de carbono na vegetação.

Para avaliar a correlação e a concordância entre as estimativas e as observações de GPP e ET, foram calculados os valores de  $r$  e do índice de concordância de Willmott ( $d$ ) (WILLMOTT *et al.*, 1985), Equação (16). Os erros associados às estimativas foram quantificados pelo erro médio absoluto (MAE), Equação (17), e a raiz do erro quadrático médio (RMSE), Equação (18). A validação foi realizada para todas as coberturas do solo e em seguida para cada cobertura.

O  $r$  varia de -1 a 1, em que valores iguais a -1 e a 1 indicando total correlação direta e inversa, respectivamente (XIAO *et al.*, 2016). O  $d$  varia de 0 a 1, com 0 indicando nenhuma concordância entre os dados estimados e os observados enquanto o valor 1 representa total concordância (WILLMOTT *et al.*, 1985). Os parâmetros de erro MAE e RMSE expressam o desvio das estimativas em relação ao observado, na unidade da variável.

$$d = 1 - \left[ \frac{\sum (P_i - O_i)^2}{\sum (|P_i - O| + |O_i - O|)^2} \right] \quad (16)$$

$$MAE = \sum_{i=1}^n \frac{|P_i - O_i|}{n} \quad (17)$$

$$RMSE = \sqrt{\frac{\sum(P_i - O_i)^2}{n}} \quad (18)$$

onde,  $P_i$  é o valor estimado,  $O_i$  o valor observado,  $O$  à média do valor observado e  $n$  indica o número total de amostras.

Foram avaliadas as tendências das estimativas de ET e GPP através do teste de Mann-Kendall (MK) e do coeficiente angular de Sen ( $s_{Sen}$ ), através dos pacotes “Kendall” e “rtrend” na linguagem R R (HAMED; RAMACHANDRA RAO, 1998; MCLEOD, 2005).

O teste MK avalia através de uma análise não-paramétrica a tendência ou não tendência de uma série, em que o coeficiente de correlação de postos tau de Kendall (Tau), acompanhado do valor-p, avalia a correlação entre duas séries, sendo uma delas geralmente o tempo (HAMED; RAMACHANDRA RAO, 1998; MCLEOD, 2005). O pressuposto do teste MK é que a série temporal possui dados independentes e distribuídos aleatoriamente, o que foi verificado por meio da Função de Autocorrelação. O Tau, assim como outros coeficientes de correlação varia de -1 a 1, em que 1 ou -1 indica a máxima correlação entre os parâmetros e uma tendência de diminuição quando  $Tau = -1$  e aumento quando  $Tau = 1$ .

Como o conjunto de dados é auto correlacionado, a magnitude das tendências nos índices climáticos extremos foi calculada usando o método *Theil-Sen*, que é insensível a outliers e pode ser significativamente mais preciso do que a regressão linear simples para dados distorcidos e heterocedásticos (ZHOU *et al.*, 2023). O *Theil-Sen* gera o  $s_{Sen}$  que ajusta de forma robusta uma reta de regressão não paramétrica para uma série, em que o valor do  $s_{Sen}$  indica o grau de crescimento ou redução da série em cada  $n$  iteração (ZHOU *et al.*, 2023). Se a tendência avaliada é uma série temporal, o valor de  $s_{Sen}$  representa o acréscimo ou decréscimo no intervalo entre um elemento e o próximo (HAMED; RAMACHANDRA RAO, 1998).

### 4.3 Resultados e discussão

#### 4.3.1 Variáveis micrometeorológicas

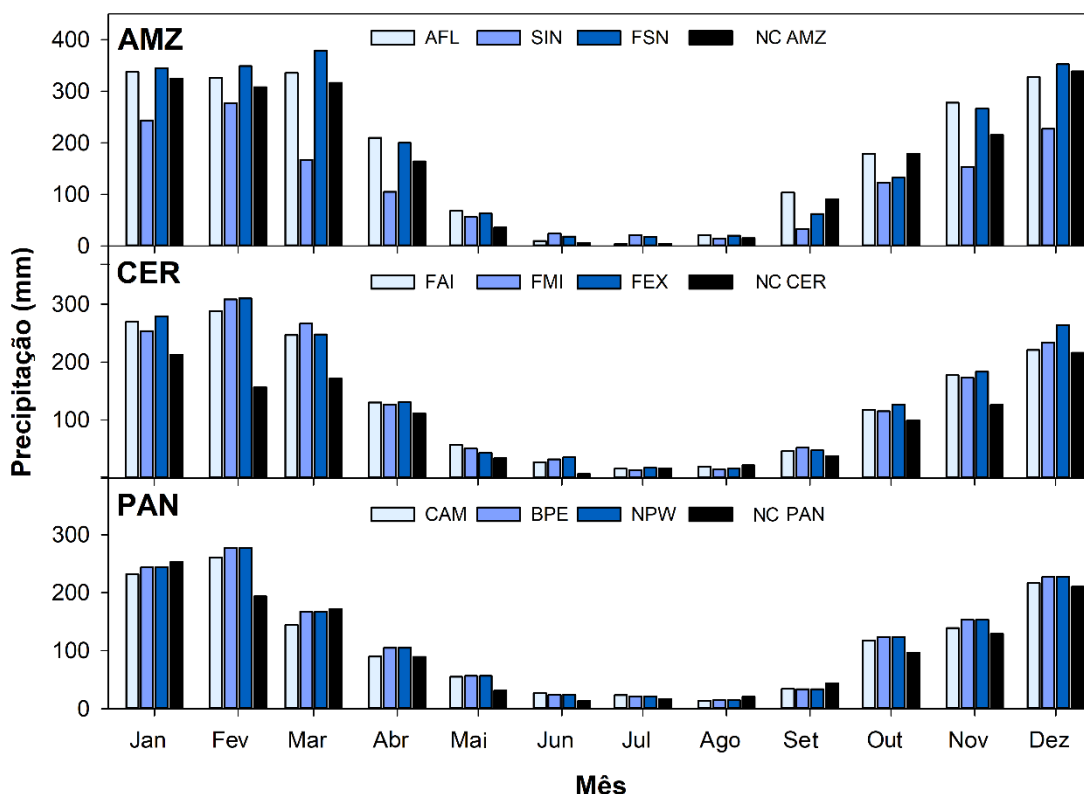
A precipitação (Ppt) anual e sazonal nos biomas (Tabela 11) teve maiores valores em relação a normal climatológica (NC), em que o Cerrado (CER ) teve maior diferença, entre 32% e 42% acima da NC enquanto na Amazônia (AMZ ) e no Pantanal (PAN ) a Ppt foi entre 8% e 20% maior que a NC. A Ppt em SIN teve diferença negativa, com 2% no período seco e 30% no período chuvoso menor que a NC.

Tabela 11 – Médias anuais e sazonais da precipitação acumulada nos pontos de amostragem de Alta Floresta (AFL), Sinop (SIN), Fazenda São Nicolau (FSN), Fazenda Arco-íris (FAI), Fazenda Experimental (FEX), Cambarazal (CAM) e Baía das Pedras (BPE e NPW), distribuídos na Amazônia (AMZ), Cerrado (CER) e Pantanal (PAN) e os valores da normal climatológica (NC) para esses biomas.

Local	Anual	Chuvoso	Seco
NC AMZ	2000,3	1847,0	153,3
AFL	2202,5	1994,7	207,7
SIN	1447,6	1297,0	150,5
FSN	2207,2	2024,8	182,4
NC CER	1212,6	1094,9	117,7
FAI	1617,5	1450,6	166,9
FMI	1640,8	1477,4	163,1
FEX	1701,8	1540,9	160,9
NC PAN	1270,7	1143,9	126,8
CAM	1355,2	1201,1	154,0
BPE	1447,6	1297,1	150,5
NPW	1447,6	1297,1	150,5

A Ppt mensal (Figura 18) estimada nos pontos amostrais teve padrão sazonal semelhante ao registrado pela NC nos três biomas. Os meses que registram os menores volume de chuva foram julho e agosto enquanto os maiores volumes ocorreram majoritariamente em fevereiro.

Figura 18 – Médias da precipitação mensal acumulada na região dos pontos amostrais Alta Floresta (AFL), Sinop (SIN), Fazenda São Nicolau (FSN), Fazenda Arco-íris (FAI), Fazenda Miranda (FMI), Fazenda Experimental (FEX), Cambarazal (CAM), Baía das Pedras (BPE) e Baía das Pedras Eddy Covariance (NPW) e Normais Climatológicas (NC) na porção de Mato Grosso correspondente aos biomas Amazônia (AMZ), Cerrado (CER) e Pantanal (PAN). As médias da precipitação mensal acumulada correspondem ao período de 2001 a 2020.



A variação do padrão de circulação atmosférica de larga escala afeta a o clima regional, causando aumento ou diminuição das amplitudes térmicas enquanto gera mudança na frequência e intensidade das chuvas (DOS SANTOS *et al.*, 2023). A variação sazonal da precipitação é controlada principalmente por sistemas atmosféricos de macro e de mesoescala. Em geral, as variabilidade da precipitação na região é relacionada aos eventos causados pelos deslocamentos da Zona de Convergência do Atlântico Sul (ZCAS), ocasionado pelo posicionamento da Alta da Bolívia (AB) no verão alinhado ao Cavado do Nordeste (ESCOBAR *et al.*, 2022). A ZCAS atua como uma corrente de umidade atmosférica, que conecta a Amazônia ao sul do Cerrado, transportando umidade da floresta amazônica para a parte sudeste do

Brasil, aumentando a as chuvas na região em que passa, sobre todo no centro oeste (PEZZI *et al.*, 2023).

Além disso o escoamento em baixos níveis da atmosfera oriundo do Oceano Atlântico Norte favorece o transporte de umidade na região central da Amazônia alimentando a ZCAS (VÁSQUEZ P. *et al.*, 2022). O Oceano Atlântico apresenta dois padrões anomalias térmicas na superfície, a positiva e negativa. As anomalias no oceano Atlântico afetam o índice de precipitação na região, de modo que fase positiva, que ocorre no atlântico norte inibe a formação de chuvas enquanto a fase negativa, no Atlântico Sul, favorece a formação de chuvas em Mato Grosso (DOS SANTOS *et al.*, 2023). Porém, esse efeito pode ocorrer de maneira retardada na região, de modo que as flutuações da precipitação não podem ser diretamente associadas as anomalias do Atlântico sem um estudo correto.

Tabela 12 – Coeficiente de correlação de Spearman entre a Precipitação e a evapotranspiração (ET) e produtividade primária bruta (GPP) nos pontos de amostragem Alta Floresta (AFL), Sinop (SIN), Fazenda São Nicolau (FSN), Fazenda Arco-íris (FAI), Fazenda Experimental (FEX), Cambarazal (CAM) e Baía das Pedras (BPE e NPW), nos biomas Amazônia (AMZ), Cerrado (CER) e Pantanal (PAN). Os valores p representados por \*\*\* são menores que 0,001, \*\* menores que 0,01, \* menores que 0,05 e – indica valores p maiores que 0,05.

Bioma	Local	ET		GPP	
		r	Valor p	r	Valor p
Amazônia	AFL	-0,50	-		
	SIN	-0,16	-		
	FSN	-0,04	-	0,46	-
Cerrado	FAI				
	FMI	0,65	***	0,58	**
	FEX	0,73	***		
Pantanal	BPE	0,74	***		
	CAM	0,78	***		
	NPW	0,77	***	0,81	***

A precipitação mensal acumulada e a média mensal da ET tiveram correlação forte e positiva nos biomas Cerrado e Pantanal (Tabela 12), indicando uma relação direta entre o fluxo de vapor de água e a sazonalidade da Ppt nesses locais. Por outro lado, a correlação entre a Ppt e a ET não foi significativa no bioma Amazônia. A Ppt e o GPP tiveram forte correlação positiva no Pantanal (NPW) e no Cerrado (FMI)

enquanto na Amazônia (FSN) a correlação não foi significativa. Esse resultado sugere que a ET e o GPP variam de acordo com os períodos seco e chuvoso no Cerrado e Pantanal. Por outro lado, na Amazônia os fluxos de vapor e de carbono não apresentam uma dependência clara com o regime de chuvas na região.

A variação da Ppt no Cerrado afeta a disponibilidade hídrica no solo, principalmente nas camadas mais superficiais (BIUDES *et al.*, 2015; OLIVEIRA *et al.*, 2005; SANTOS *et al.*, 2020). Como consequência, a vegetação do Cerrado desenvolveu diversas adaptações morfológicas e fenológicas que aumentaram a eficiência do uso da água (HARIDASAN, 2008). Entre essas adaptações estão os sistemas radiculares espessos e profundos, o efeito de dormência durante o período seco, após abscisão foliar e morte dos ramos (FURQUIM *et al.*, 2018).

Os resultados corroboram com outros estudos realizados na região da área de estudo, em que vêm sendo destacados importantes aspectos a respeito da dependência da vegetação no Cerrado em relação a precipitação (BIUDES *et al.*, 2015; FAUSTO *et al.*, 2014). Em geral variação da oferta hídrica no solo afeta a evaporação na superfície além de limitar o desenvolvimento da vegetação, prejudicando processos fisiológicos e a produção de folhas (FAUSTO *et al.*, 2014).


#### 4.3.2 Validação e análise dos produtos de ET e GPP

As médias das estimativas de ET tiveram valores que diferiram em diferentes graus, nos biomas Amazônia, Cerrado e Pantanal, com a maioria dos produtos apresentando estimativa maior que as amostras *in situ*, principalmente na Amazônia e no Cerrado (Figura 19). O produto ERA5 teve média anual que não diferiu significativamente das amostras *in situ* nos três biomas. As médias do produto GLEAM no período seco não foram diferentes das médias das amostras *in situ* nos biomas Amazônia e Cerrado, mas foram diferentes no Pantanal. As médias do produto Terra Climate, no período chuvoso, não foram diferentes das médias das amostras *in situ* nos biomas Amazônia e Cerrado enquanto as médias no período chuvoso do produto ERA5 não foram diferentes no Cerrado e no Pantanal.

A ET medida não teve diferença nas suas médias sazonais em AMZ e no CER, enquanto em PAN a média do período seco foi menor que no chuvoso. Esse padrão foi semelhante nas estimativas dos produtos FLDAS, SEBOP, PML e SEBAL. Isso

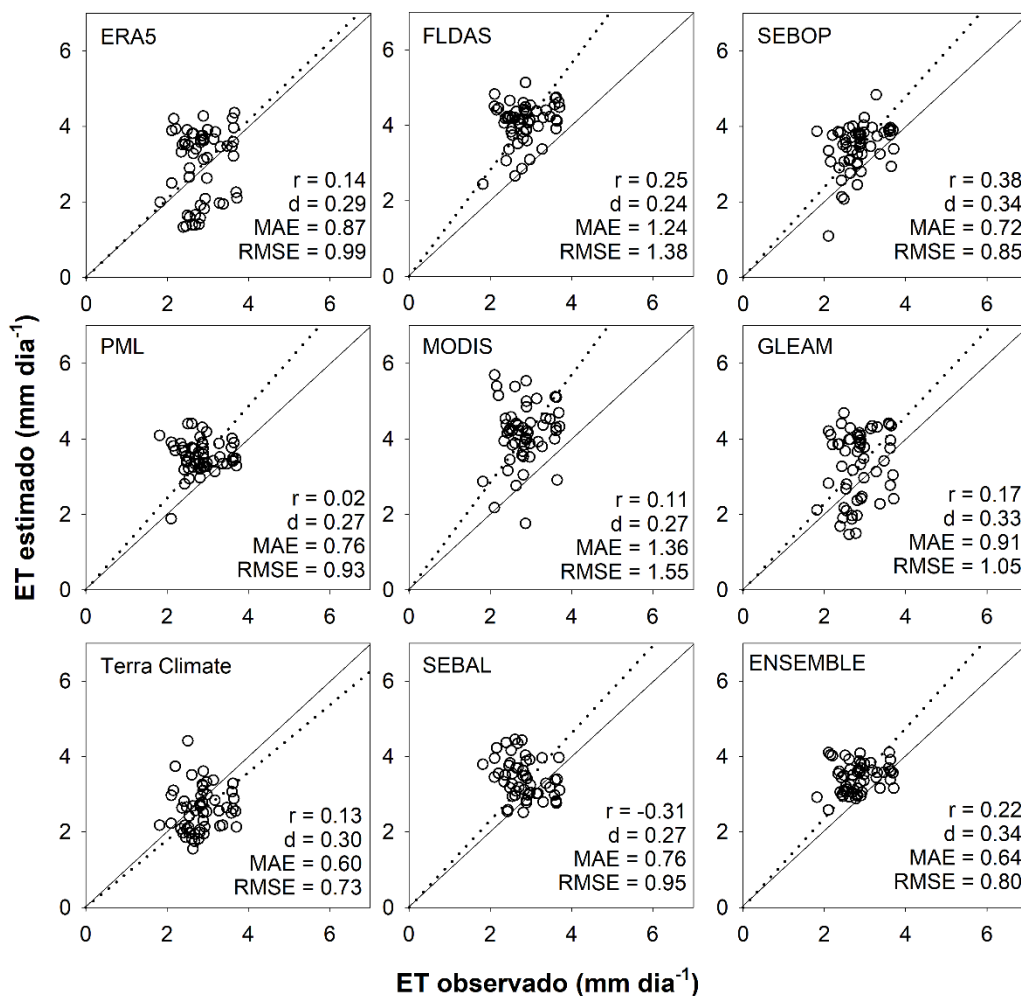
significa que esses produtos foram capazes de reproduzir a sazonalidade da ET observada nos dados coletados *in situ*.

Figura 19 – Média anual e sazonal, e intervalo de confiança, da evapotranspiração (ET; mm dia<sup>-1</sup>) amostrada *in situ* (*Ground*) e estimada pelos produtos ERA5, FLDAS, SEBOP, PML, MODIS, GLEAM, Terra Climate, SEBAL e pela média ensemble desses produtos, nos biomas Amazônia (AMZ), Cerrado (CER) e Pantanal (PAN) em Mato Grosso no período de 2001 a 2020.



As estimativas da ET na Amazônia tiveram os menores valores de correlação ( $r$ ) e índice de Willmott ( $d$ ), com  $r$  variando de 0,02 a 0,38 e  $d$  de 0,24 a 0,34 (Figura 20). O produto SSEBop teve os maiores valores de  $r$  e  $d$  na Amazônia enquanto o produto FLDAS teve os menores valores. O MAE na Amazônia variou de 0,60 a 1,36 mm dia<sup>-1</sup> e RMSE variou de 0,73 a 1,55 mm dia<sup>-1</sup>. As estimativas do produto Terra Climate tiveram os menores valores de MAE e RMSE na Amazônia, enquanto o produto MODIS teve os maiores.

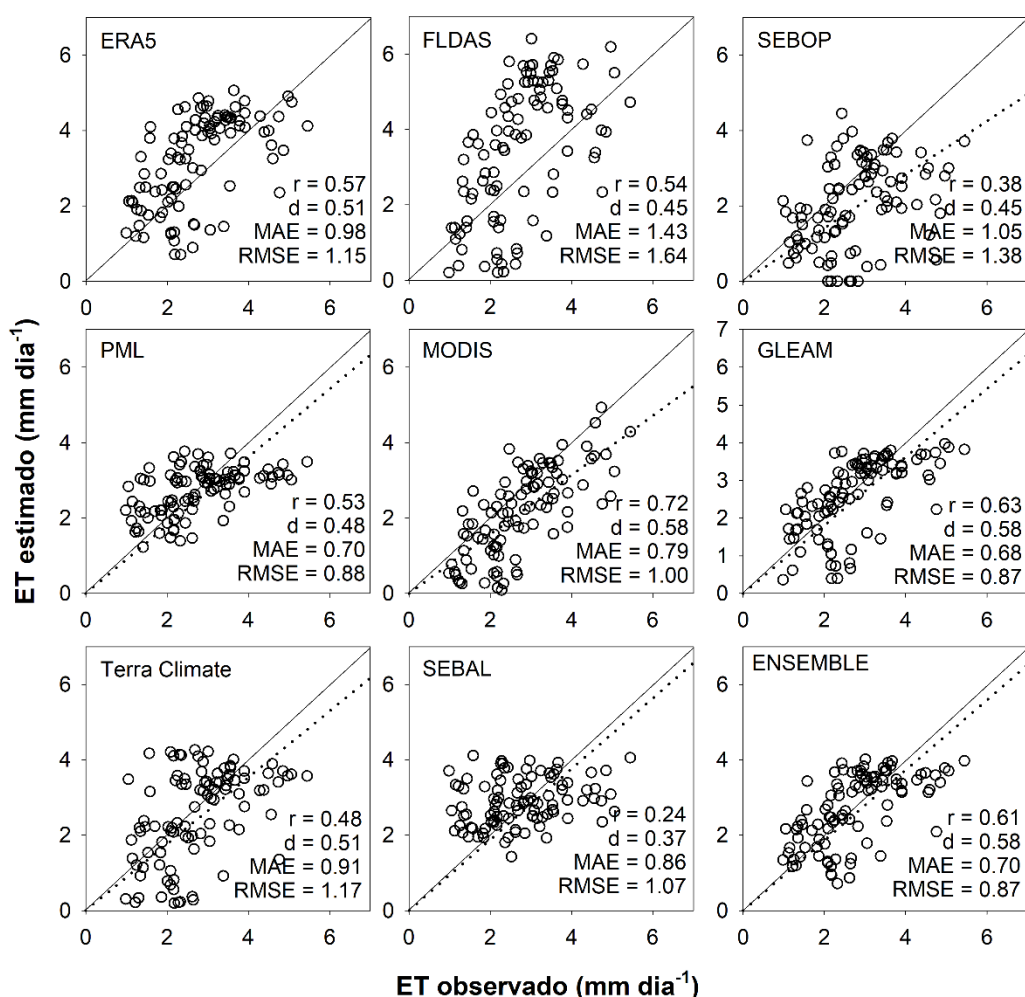
Figura 20 – Evapotranspiração (ET;  $\text{mm dia}^{-1}$ ) estimada pelos produtos ERA5, FLDAS, SSEBop, PML, MODIS, GLEAM, Terra Climate e SEBAL, comparada com amostras *in situ* de ET, regressões lineares (linha tracejada) e valores de coeficiente de correlação de Spearman ( $r$ ), índice de concordância de Willmott ( $d$ ), erro médio absoluto (MAE;  $\text{mm dia}^{-1}$ ) e raiz do erro quadrático médio (RMSE;  $\text{mm dia}^{-1}$ ), na Amazônia (AMZ) de Mato grosso de 2001 a 2020. A linha preta diagonal contínua indica a região de perfeito ajuste das estimativas.



As menores das estimativas de ET com os dados medidos na Amazônia estão associadas as mudanças sazonais dos padrões de circulação atmosférica na região e a dificuldade de obtenção de imagens da superfície sem nebulosidade (ESPINOZA *et al.*, 2012; SALGADO *et al.*, 2019). Durante o ano a região sofre influência de sistemas tropicais e extratropicais, em que anomalias de vento sul e sua convergência com os ventos alísios progridem e geram diversos padrões de circulação. Essa variabilidade de padrões implica num pior desempenho dos modelos que tentam reproduzir a variabilidade de grandezas associadas a precipitação na Amazônica, tendo a menor

correlação e maiores erros na parte norte do bioma (ESPINOZA *et al.*, 2012). Além disso a nebulosidade na zona de convergência reduz a visibilidade dos satélites, perturbando ou reduzindo o conjunto de dados de sensoriamento remoto à cerca da superfície (ASNER, 2001; BEZERRA *et al.*, 2023).

Figura 21 – Evapotranspiração (ET;  $\text{mm dia}^{-1}$ ) estimada pelos produtos ERA5, FLDAS, SSEBop, PML, MODIS, GLEAM, Terra Climate e SEBAL, comparada com amostras *in situ* de ET, regressões lineares (linha tracejada) e valores de coeficiente de correlação de Spearman ( $r$ ), índice de concordância de Willmott ( $d$ ), erro médio absoluto (MAE;  $\text{mm dia}^{-1}$ ), e raiz do erro quadrático médio (RMSE;  $\text{mm dia}^{-1}$ ), no Cerrado (CER) de Mato Grosso de 2001 a 2020. A linha preta diagonal indica a região de perfeito ajuste das estimativas.

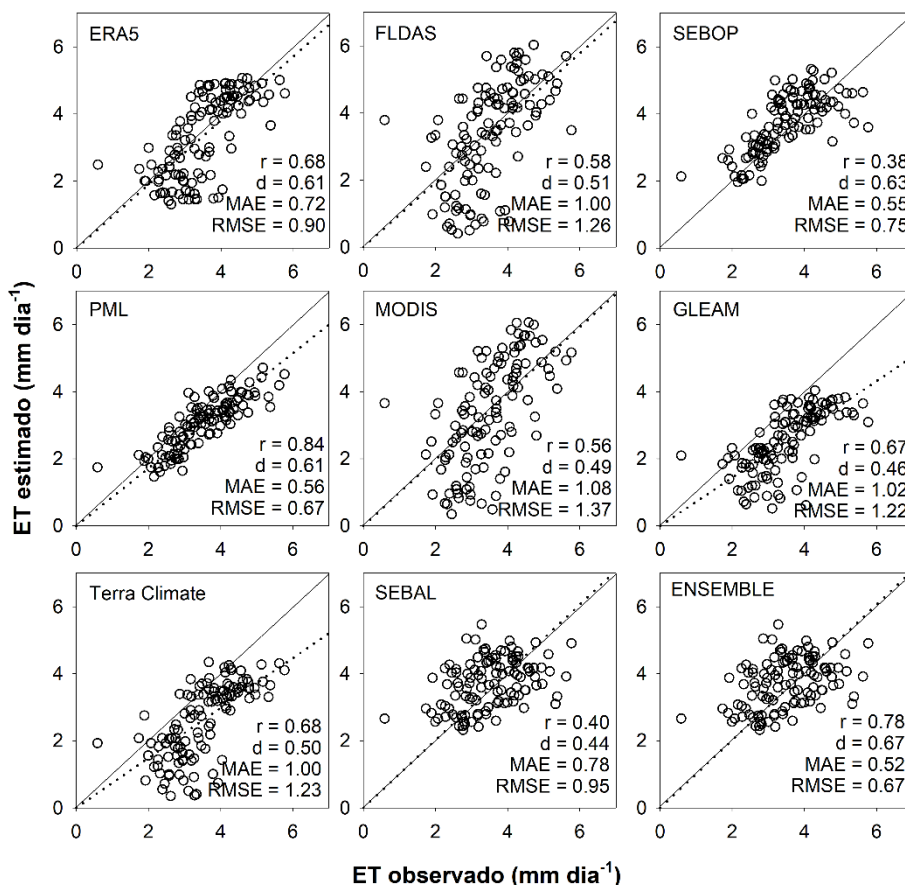


As estimativas de ET no Cerrado tiveram valores de  $r$  que variaram de 0,24 a 0,72 e  $d$  que variaram de 0,45 a 0,58 enquanto o MAE variou de 0,68 a 1,43  $\text{mm dia}^{-1}$  e o RMSE de 0,87 a 1,64  $\text{mm dia}^{-1}$  (Figura 21). O produto MODIS teve os maiores

valores de  $r$  e  $d$  no Cerrado enquanto o produto SEBAL teve os menores valores. As estimativas do produto GLEAM tiveram os menores erros no Cerrado, com menores valores de MAE e RMSE, enquanto o produto FLDAS teve os maiores erros.

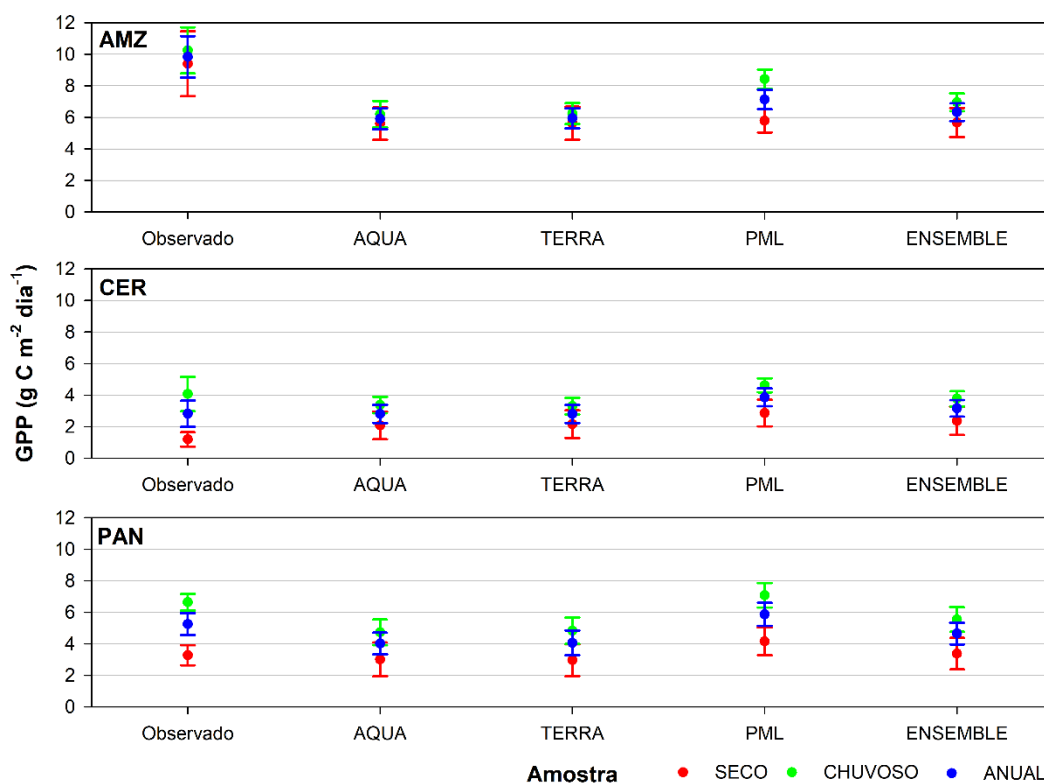
As estimativas da ET no Pantanal tiveram os maiores valores de correlação e índice de Willmott, com  $r$  variando de 0,02 a 0,38 e  $d$  de 0,24 a 0,34, enquanto tiveram os menores erros, com MAE de 0,60 a 1,36  $\text{mm dia}^{-1}$  e RMSE de 0,73 a 1,55  $\text{mm dia}^{-1}$  (Figura 20). Os produtos PML e ENSEMBLE tiveram os maiores valores de  $r$  e  $d$  no Pantanal enquanto o produto SEBAL teve os menores valores. As estimativas dos produtos PML e ENSEMBLE tiveram os menores erros no Pantanal, com menores valores de MAE e RMSE, enquanto o produto MODIS teve os maiores erros.

Figura 22 – Evapotranspiração (ET;  $\text{mm dia}^{-1}$ ) estimada pelos produtos ERA5, FLDAS, SSEBop, PML, MODIS, GLEAM, Terra Climate e SEBAL, comparada com amostras *in situ*, regressões lineares (linha tracejada) e valores de coeficiente de correlação de Spearman ( $r$ ), índice de concordância de Willmott ( $d$ ), erro médio absoluto (MAE;  $\text{mm dia}^{-1}$ ), e raiz do erro quadrático médio (RMSE;  $\text{mm dia}^{-1}$ ), no Pantanal (PAN) de 2001 a 2020. A linha preta diagonal indica a região de perfeito ajuste das estimativas.



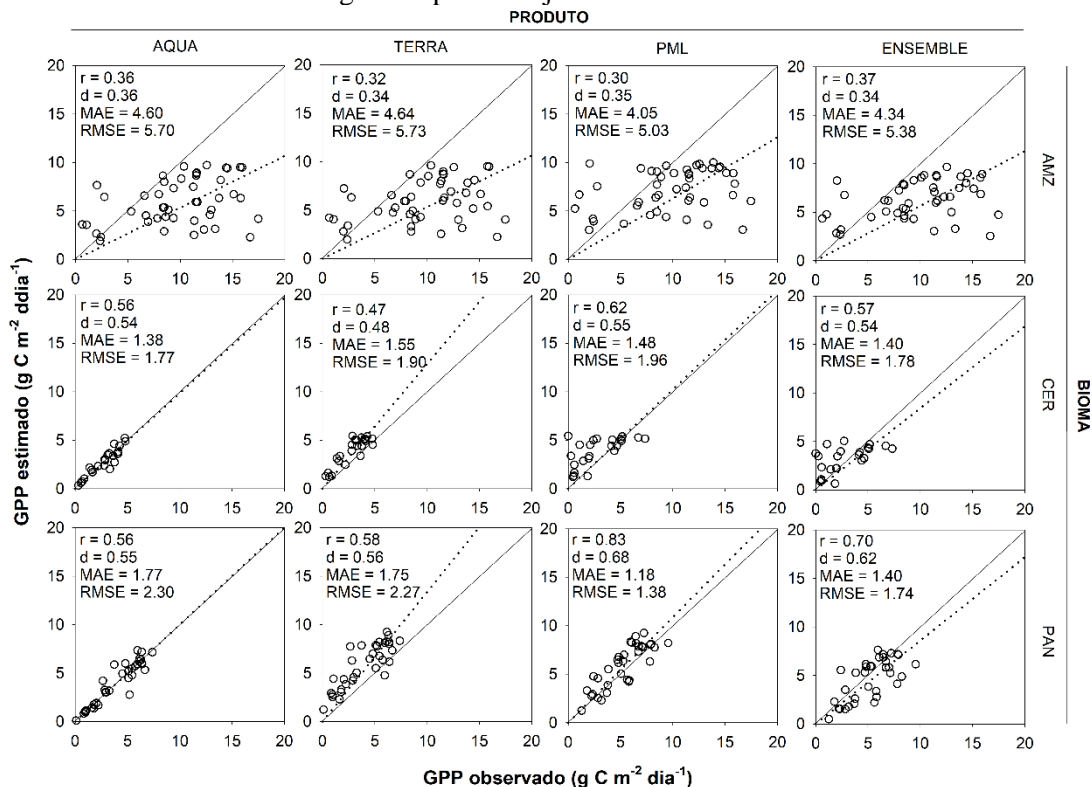
A maioria das médias das estimativas de GPP não diferiu significativamente da amostra *in situ*, principalmente nos biomas Cerrado e Pantanal (Figura 23). As estimativas que diferiram da amostra *in situ* apresentaram majoritariamente subestimativa de 1% a 40%. Em geral a sazonalidade teve pouco efeito nas médias dos produtos de GPP, de modo que as médias entre o período seco, chuvoso e a média anual não foram significativamente diferentes, sendo observado esse mesmo padrão nas amostras *in situ*. As médias anuais de todos os produtos de GPP nos biomas Cerrado e Pantanal não diferiram significativamente das médias das amostras *in situ*. As médias no período seco, em geral foram significativamente diferentes das amostras *in situ* em todos os três biomas. As médias no período chuvoso não foram significativamente diferentes das amostras *in situ* no bioma Cerrado. O produto PML teve média no período chuvoso que não diferiram significativamente das amostras *in situ* nos três biomas.

Figura 23 – Média anual e sazonal, e intervalo de confiança, da produtividade primária bruta (GPP;  $\text{g C m}^{-2} \text{ dia}^{-1}$ ) amostrada *in situ* (Ground) e estimada pelos produtos ERA5, FLDAS, SSEBop, PML, MODIS, GLEAM, Terra Climate, SEBAL e pela média ensemble desses produtos, nos biomas Amazônia (AMZ), Cerrado (CER) e Pantanal (PAN) em Mato Grosso no período de 2001 a 2020.



Assim como as estimativas de ET, o GPP na Amazônia teve os menores valores de correlação ( $r$ ) e índice de Willmott ( $d$ ), com  $r$  variando de 0,30 a 0,37 e  $d$  de 0,34 a 0,36 (Figura 24). O ENSEMBLE teve o maior valor de  $r$  enquanto o produto AQUA teve o maior valor de  $d$  na Amazônia. O MAE e o RMSE na Amazônia tiveram os maiores valores em relação aos demais biomas, com o MAE variando de 4,05 a 4,64  $\text{g C m}^{-2} \text{ dia}^{-1}$  e o RMSE de 5,03 a 5,73  $\text{g C m}^{-2} \text{ dia}^{-1}$ . As estimativas do produto PML tiveram os menores valores de MAE e RMSE na Amazônia enquanto o produto TERRA teve os maiores erros.

Figura 24 – Produtividade primária bruta (GPP;  $\text{g C m}^{-2} \text{ dia}^{-1}$ ) estimada pelos produtos MODIS AQUA, MODIS TERRA e PML, comparada com amostras *in situ* de ET na Amazônia (AMZ), no Cerrado (CER) e no Pantanal (PAN), com as respectivas regressões lineares (linha tracejada) e valores de coeficiente de correlação de Spearman ( $r$ ), índice de concordância de Willmott ( $d$ ), erro médio absoluto (MAE;  $\text{g C m}^{-2} \text{ dia}^{-1}$ ), e raiz do erro quadrático médio (RMSE;  $\text{g C m}^{-2} \text{ dia}^{-1}$ ), de 2001 a 2020. A linha preta diagonal indica a região de perfeito ajuste das estimativas.



Os valores de  $r$  e  $d$  para as estimativas de GPP no Cerrado variaram de 0,47 a 0,62 e 0,48 a 0,55, respectivamente (Figura 24). O produto PML teve os maiores valores de  $r$  e  $d$  no Cerrado enquanto o produto TERRA teve os menores valores. O MAE e o RMSE das estimativas no Cerrado variaram de 1,38 a 1,55  $\text{g C m}^{-2} \text{ dia}^{-1}$  e 1,77 a 1,96  $\text{g C m}^{-2} \text{ dia}^{-1}$ , respectivamente. As estimativas do produto AQUA tiveram os menores valores de MAE e RMSE enquanto os produtos TERRA e PML tiveram os maiores erros.

As estimativas de GPP no Pantanal tiveram os maiores valores de correlação e índice de Willmott, com  $r$  variando de 0,56 a 0,83 e  $d$  de 0,55 a 0,68 (Figura 24). O MAE e o RMSE das estimativas no Pantanal variaram de 1,18 a 1,77  $\text{g C m}^{-2} \text{ dia}^{-1}$  e 1,38 a 2,30  $\text{g C m}^{-2} \text{ dia}^{-1}$ , respectivamente. As estimativas do produto PML tiveram os maiores valores de  $r$  e  $d$  e os menores valores de MAE e RMSE enquanto o produto AQUA teve os menores valores de  $r$  e  $d$  e os maiores erros.

Em geral, as estimativas dos produtos de GPP apresentaram um padrão de subestimativa em relação as amostras *in situ*, evidenciado pelas médias sazonais e pela regressão linear com inclinação menor que a reta de referência (linha preta contínua) (Figura 23; Figura 24). As estimativas de GPP no Cerrado tiveram padrões de subestimativa e superestimativa entre os produtos. As estimativas de GPP no pantanal tiveram uma maior ocorrência de padrões de superestimativa. As regressões lineares dos produtos AQUA e PML foram as que mais se aproximaram da reta de referência, corroborando com os seus desempenhos na análise de correlação, concordância e erro.

Os produtos de ET e GPP acompanharam majoritariamente a sazonalidade das amostras *in situ*, principalmente no Pantanal, com maiores médias no período chuvoso e menores no período seco (Figura 19 e Figura 23). Esse resultado indica que a ET e GPP no Pantanal tiveram maior sensibilidade a sazonalidade da precipitação, o que corrobora com os resultados da Tabela 12, em que a correlação entre ET e GPP com a Ppt foi maior no Pantanal. A análise de correlação, concordância e erro das estimativas de ET e GPP nas figuras Figura 20, Figura 21, Figura 22 e Figura 24 também corroborou com esses resultados, em que as estimativas de ET no Pantanal apresentam os melhores desempenhos.

Os produtos ERA5, Terra Climate e GLEAM tiveram os melhores desempenhos na comparação das suas médias com as amostras *in situ*. Por outro lado,

na análise de erro, concordância e correlação os produtos com os melhores desempenhos foram SSEBop, GLEAM e PML e ENSEMBLE.

Os produtos ERA5, Terra Climate e GLEAM tiveram os melhores desempenhos na comparação das suas médias de ET com as amostras *in situ*. Por outro lado, na análise de erro, concordância e correlação os produtos de ET com os melhores desempenhos foram SSEBop, GLEAM e PML e ENSEMBLE. O produto PML teve o melhor desempenho na comparação das suas médias de GPP com as amostras *in situ* e o melhor desempenho na análise de correlação, concordância e erro.

O ENSEMBLE ficou entre os três melhores desempenhos nas estimativas de ET e entre os dois melhores nas estimativas de GPP nos três biomas, quando consideradas as maiores correlações e concordâncias e menores erros. Além disso, o produto ENSEMBLE possui resolução espacial maior que os produtos de melhor desempenho na validação da ET (FLDAS, GLEAM, MODIS, PML, SSEBop) e GPP (PML e AQUA). Dessa forma, o ENSEMBLE é a melhor alternativa para estimar a ET e GPP nos biomas Amazônia, Cerrado e Pantanal, pois permite visualizar os gradientes com maior resolução espacial e melhor qualidade nas estimativas.

Nas estimativas dos produtos ERA5 e GLEAM validados em um conjunto de 721 estações na China, a evapotranspiração foi estimada em escala mensal e anual, resultando em  $r$  igual a 0,82 e 0,56 e RMSE igual a 29,6 mm month<sup>-1</sup> e 49,1 mm month<sup>-1</sup> (XU *et al.*, 2024). O produto SEBAL foi validado em área de lavoura comercial, no oeste do estado de São Paulo, resultando em RMSE igual a 0,72 mm dia<sup>-1</sup> (GONÇALVES *et al.*, 2022). O produto MOD16A2 avaliado nos pampas Argentinos apresentou RMSE 3,4 mm dia<sup>-1</sup> (DEGANO *et al.*, 2021). Em estudo global realizado com dados de 645 pontos amostrais, os produtos ERA5, FLDAS, PML, SEBAL, SSEBop, MODIS (MOD16A2) foram avaliados, em que o PML foi apontado como o que melhor concordou com a ET observada, com o menor RMSE enquanto o produto FLDAS teve o maior RMSE (ELNASHAR *et al.*, 2021).

Em área de Cerrado Campo Limpo, em Mato Grosso, o GPP estimado pelo produto TERRA (MOD17A2) foi validado e resultou em  $r$  igual a 0,77,  $d$  igual a 0,85, MAE igual a 1,11 e RMSE igual a 1,45 (BIUDES *et al.*, 2021). O produto MOD17A2H foi avaliado em pontos amostrais em áreas úmidas de restinga no estuário do rio Yangtze, China continental, resultado em valores de RMSE de 2,61 a 3,08 g C m<sup>-2</sup> dia<sup>-1</sup>.

<sup>1</sup> (YANG *et al.*, 2023). As estimativas de GPP do produtos TERRA e AQUA foram avaliadas em um conjunto de 78 pontos amostrais, distribuídos no globo, e resultaram em valores RMSE que variaram de 2,32 a 2,96 g C m<sup>-2</sup> dia<sup>-1</sup> e de 2,36 a 2,88 g C m<sup>-2</sup> dia<sup>-1</sup>, respectivamente (ZHANG *et al.*, 2023). O produto PML foi avaliado, em relação as suas estimativas de GPP em 95 pontos amostrais distribuídos no globo, resultando em RMSE igual a 1,99 g C m<sup>-2</sup> dia<sup>-1</sup> (ZHANG *et al.*, 2019).


As estimativas de ET e GPP pelos MMEs no Mato Grosso tiveram regiões com diferentes padrões sazonais. A região ocupada pelo bioma Amazônia, apresentou a menor variação sazonal da ET, com a média no período seco 9% menor que no período chuvoso enquanto a média do GPP 11% menor (Tabela 13). A ET e o GPP no Cerrado tiveram a maior variação sazonal, com a média da ET no período seco 35% menor que no chuvoso enquanto o GPP no período seco teve média 53% menor que no chuvoso. No Pantanal, a média da ET e do GPP no período seco foram 30% e 48% menor que no período chuvoso, respectivamente.

A distribuição dos dados de ET e GPP no histograma teve maior dispersão no período seco, com maior dispersão no bioma Amazônia (Tabela 13; Figura 25 e Figura 26). Além disso, a ET teve distribuição assimétrica nos três biomas, com maior assimetria no período seco, nos três biomas, sobretudo no Cerrado. Não foi possível avaliar quantitativamente a assimetria da distribuição de dados do GPP devido ao seu padrão bimodal.

Tabela 13 – Média, intervalo de confiança (ic), desvio padrão (SD) e coeficiente de assimetria da evapotranspiração (ET, mm/dia) e da produtividade primária bruta (GPP; gC m<sup>-2</sup>dia<sup>-1</sup>) estimada por *Multi-model Ensemble* (MME), nos biomas de Mato Grosso para os períodos chuvoso e seco de 2001 a 2020.

Bioma	Período	ET		GPP	
		Média ± ic	Assimetria	Média ± ic	Assimetria
Amazônia	Chuvoso	3,73 ± 0,14	0,12	7,20 ± 0,87	-0,80
	Seco	3,38 ± 0,13	-0,68	6,38 ± 0,76	-0,74
Cerrado	Chuvoso	3,55 ± 0,10	0,24	4,45 ± 1,85	0,46
	Seco	2,30 ± 0,24	1,00	2,10 ± 0,83	1,26
Pantanal	Chuvoso	4,07 ± 0,12	0,25	6,60 ± 0,40	-0,30
	Seco	2,84 ± 0,18	0,50	3,45 ± 0,77	0,05

Figura 25 – Histograma da evapotranspiração (ET; mm dia<sup>-1</sup>) estimada pelas médias mensais dos produtos componentes *Multi-model Ensemble* (MME), na Amazônia (AMZ), no Cerrado (CER) e no Pantanal (PAN) de Mato Grosso de 2001 a 2020




O bioma Cerrado e Pantanal tiveram assimetria positiva, indicando que a maior parte da área de estudo assumiu valores de ET maiores que a média, enquanto a assimetria da ET na Amazônia foi positiva no período chuvoso e negativa no seco. Esses dois padrões de distribuição na Amazônia ocorrem devido a sua fitofisionomia composta por locais de vegetação campestre, mais sensível as mudanças na precipitação, e locais com florestas, que em geral resistem por mais tempo ao período seco, mantendo sua folhagem e reduzindo pouco sua evapotranspiração. A vegetação do Cerrado e do Pantanal, por outro lado, é em geral mais sensível a sazonalidade da oferta hídrica, de modo que a vegetação reduz drasticamente a sua taxa de crescimento

e a respiração, resultando em menores valores de ET (BIUDES *et al.*, 2015; FURQUIM *et al.*, 2018).

As intersecções entre os histogramas do período seco e chuvoso mostraram que a ET na Amazônia teve menor variação sazonal, ou seja, os pixels assumiram valores próximos nos dois períodos. Nos biomas Cerrado e Pantanal, a assimetria da ET no período chuvoso e seco foi diferente, porém não houve inversão na distribuição dos dados. No Pantanal a região de intersecção foi a menor, significando que houve uma maior variação sazonal na área de estudo, corroborando com as médias para esses períodos.

Figura 26 – Histograma da produtividade Primária Bruta (GPP;  $\text{gC m}^{-2} \text{dia}^{-1}$ ) estimada pelas médias mensais dos produtos componentes *Multi-model Ensemble* (MME), na Amazônia (AMZ), no Cerrado (CER) e no Pantanal (PAN) de Mato Grosso de 2001 a 2020

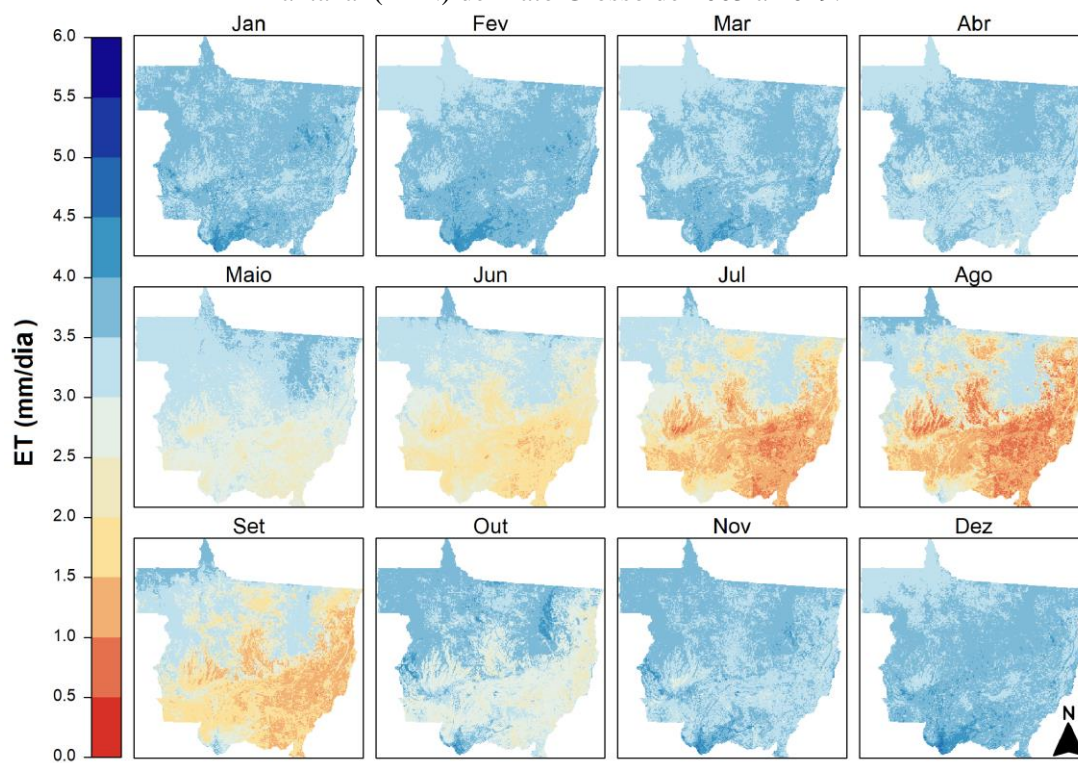


O GPP da vegetação amazônica revela a persistência da vegetação em manter sua taxa fotossintética ao longo do ano, de modo que a distribuição dos dados no período chuvoso e seco tiveram apenas uma mudança na porção esquerda do histograma. Essa diferença é devido a mudança dos processos fisiológicos da vegetação campestre, que no período seco entra na fase de reprodução, reduzindo a fotossíntese, ressecando e produzindo sementes. Nos biomas Cerrado e Pantanal a sensibilidade da vegetação as mudanças no regime de chuva e a oferta hídrica no solo gerou diminuição do GPP sem mudar a forma do histograma.

Além disso, no histograma da ET e do GPP no cerrado existe uma porção da vegetação que não acompanha o restante dos locais na dinâmica sazonal, possivelmente por se tratar de uma vegetação de área de transição em que as características do Bioma Cerrado e Amazônia se misturam (MARQUES *et al.*, 2020; SOUZA *et al.*, 2014). A vegetação na Região Amazônica em geral tem menor resposta a sazonalidade a da precipitação, comparada aos Biomas Cerrado e Pantanal (BIUDES *et al.*, 2022). Além disso, os locais com uso e cobertura do solo alterado causam mudança na distribuição dos dados, de modo que esse efeito vem sendo estudado por diversos autores (MACHADO *et al.*, 2020; PAVÃO, 2021; REZENDE *et al.*, 2022).

O GPP e a ET no Mato Grosso tiveram padrão espaço-temporal semelhante a classificação climática da região, com predominância das maiores amplitudes de valores de ET no sul do estado, maiores valores durante o período chuvoso (outubro a abril) e menores valores durante o período seco (maio a setembro) (ALVARES *et al.*, 2013) (Figura 27 e Figura 28). Além disso, as características fito fisionômicas da superfície contribuíram para a distribuição espacial e temporal da ET e do GPP, em que regiões com maior concentração arbóreas tiveram maiores valores de ET e GPP enquanto em locais com vegetação arbustiva ou rasteira ocorreram os menores valores. Por outro lado, em locais com vegetação de ciclo fenológico mais intenso, que apresentam redução da folhagem, interrupção da fotossíntese e diminuição da respiração foram observadas as maiores variações sazonais de ET e GPP.

Figura 27 – Evapotranspiração (ET; mm dia<sup>-1</sup>) estimada pelas médias mensais dos produtos componentes *Multi-model Ensemble* (MME), na Amazônia (AMZ), no Cerrado (CER) e no Pantanal (PAN) de Mato Grosso de 2003 a 2019.



A região sudeste do estado apresenta a menor concentração de vegetação nativa e a menor densidade de biomassa vegetal, com a maior parte ocupada pelo bioma Cerrado. A vegetação do Cerrado tem um ciclo fenológico caracterizado pela perda da folhagem e redução da taxa de crescimento no período seco enquanto no período chuvoso ocorre a renovação das folhas. A diminuição da área foliar durante o período seco pela perda de folhagem da vegetação reduz a ET. Por outro lado, a maior taxa de crescimento da vegetação durante a renovação da folhagem no período chuvoso aumenta a taxa de assimilação do carbono nas plantas, refletindo em maiores valores de GPP.

A região noroeste de Mato Grosso, ocupada pela Amazônia possui maior densidade de vegetação arbórea, com ecossistemas caracterizados pela alta taxa de crescimento da vegetação durante todo o ano, em decorrência do longo período chuvoso (Figura 17). Dessa forma, a oferta hídrica no solo e a umidade produzida pela própria vegetação favoreceu um ambiente úmido e propício para a manutenção da ET e GPP durante todo o ano.

Figura 28 – Produtividade Primária Bruta (GPP;  $\text{gC m}^{-2} \text{dia}^{-1}$ ) estimada pelas médias mensais dos produtos componentes *Multi-model Ensemble* (MME), na Amazônia (AMZ), no Cerrado (CER) e no Pantanal (PAN) de Mato Grosso de 2003 a 2019.

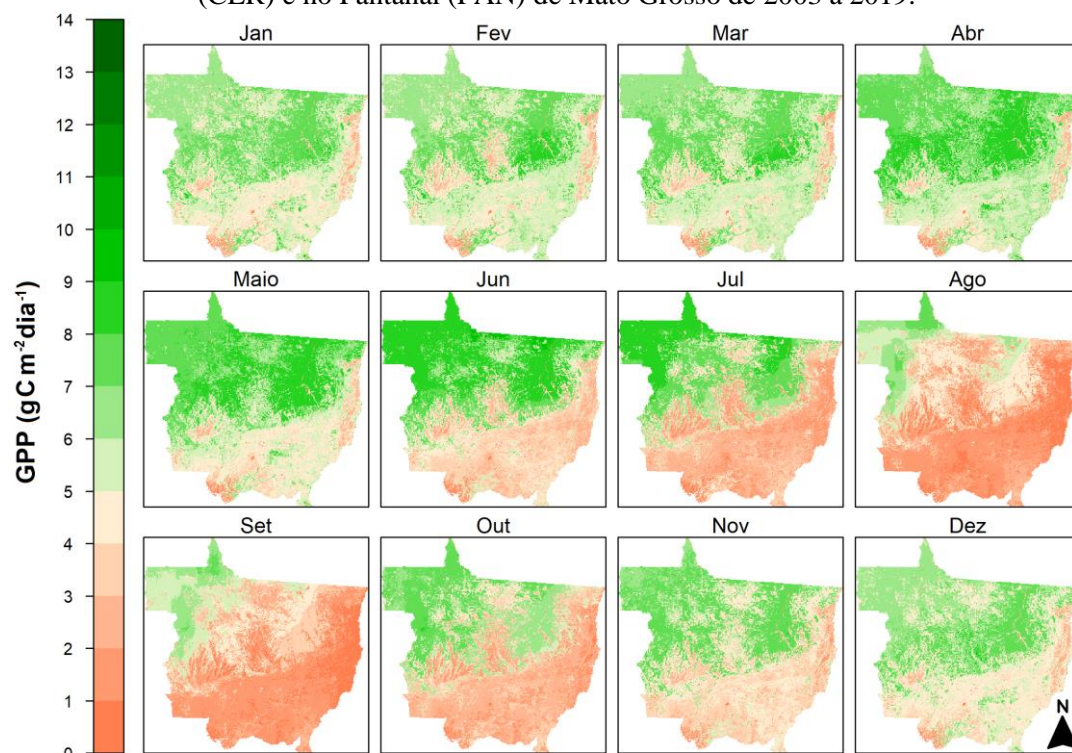
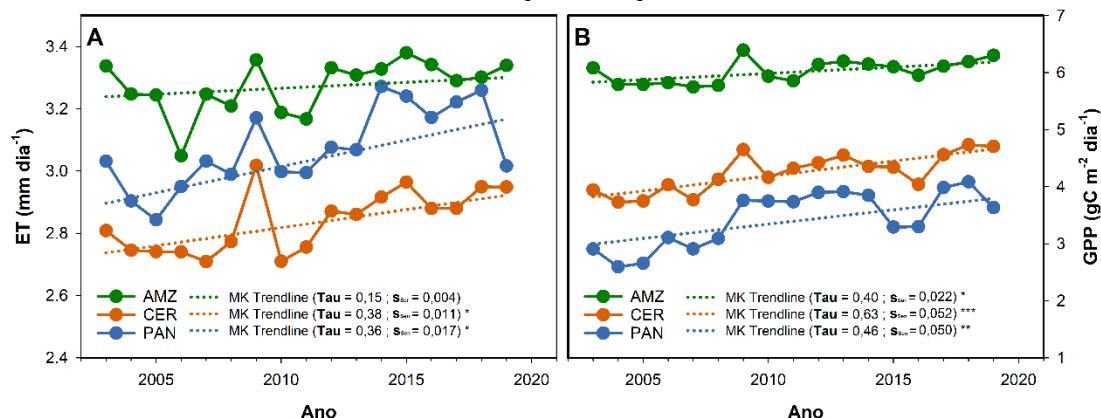


Figura 29 – Médias anuais e modelo de tendência linear (*Trendline*), Tau de Kendall (Tau) e coeficiente de tendência de Sen (Sen' slope), obtidos pelos teste de Mann-Kendall e Teste de Mann-Kendall modificado sobre a evapotranspiração (ET;  $\text{mm dia}^{-1}$ ) e produtividade primária bruta (GPP;  $\text{gC m}^{-2} \text{dia}^{-1}$ ) estimados pelo *Multi-model Ensemble* (MME), na Amazônia (AMZ), no Cerrado (CER) e no Pantanal (PAN) de Mato Grosso de 2003 a 2019. A simbologia \*\*\* indica valor p menor que 0,001, \*\* indica valor p menor que 0,01 e \* indica valor p menor que 0,05.



As médias anuais do GPP nos biomas Cerrado e Pantanal tiveram tendência significativa de aumento ao longo dos anos (Figura 29). O teste de Mann-Kendall para

a ET resultou em valores de tendência de aumento de 0,01 mm ao ano. As tendências das médias anuais ET na Amazônia e no Pantanal, não foram significativas, de modo que nada será afirmado sobre essas tendências. O GPP teve tendência de aumento nos três biomas, com maiores valores no Cerrado e no Pantanal, de 0,05 mm ao ano em ambos.

O estado de Mato Grosso faz parte do arco do desmatamento, em que de 2003 a 2019 aproximadamente 6% da área total do estado foi convertida de ecossistema natural para área antropizada (ALDRICH *et al.*, 2012; DA SILVA ARRUDA *et al.*, 2024; SOUZA *et al.*, 2023). A maioria dos estudos que investigam os efeitos do desmatamento na superfície já têm demonstrado que a mudança na cobertura do solo, sobretudo a conversão de vegetação nativa em área antropizada altera a dinâmica dos fluxos de energia e massa na superfície. Porém, nesse estudo não foi realizada uma análise de correlação entre a série histórica de cobertura do solo e a ET e o GPP, de modo que não é possível afirmar que nesse caso esses parâmetros apresentam correlação significativa.

Alguns autores apontam a existência de uma correlação entre o GPP e as ocorrências de incêndios no Cerrado e no Pantanal (ROSSI; SANTOS, 2020). Os incêndios que ocorrem de forma natural contribuem para o ciclo de renovação da biodiversidade no Cerrado, de modo que a vegetação desse bioma apresenta uma resistência e uma adaptação ao fogo (DAIREL; FIDELIS, 2024). No Pantanal, combinação de forte estiagem e altas temperaturas, em período mais seco, favorece a ocorrência de incêndios, reduzindo a biomassa vegetal seca e abrindo espaço no solo para o crescimento de novas plantas (MARQUES *et al.*, 2021). Por outro lado, o aumento da frequência e intensidade dos eventos de incêndio pode forçar a vegetação a responder de forma mais intensa no processo de recuperação da folhagem e consequentemente na assimilação de carbono por fotossíntese.

As variações interanuais da ET e do GPP no Cerrado e Pantanal ocorrem principalmente em resposta a variação de parâmetros como a precipitação e o conteúdo de água no solo, com forte correlação (BIUDES *et al.*, 2021). Em períodos mais chuvosos, a oferta hídrica somada a abundância de energia solar também favorece o desenvolvimento da vegetação, aumentando a sua taxa de crescimento (DANELICHEN *et al.*, 2016).

De modo geral, a combinação de dados de sensoriamento remoto e de reanálise é uma possibilidade segura para estudos que buscam entender a dinâmica dos fluxos de massa, em particular o vapor de água e o carbono. Nesse sentido esses dados fornecem uma perspectiva ampla do cenário regional, de modo que podem auxiliar numa gestão mais democrática e sustentável dos recursos naturais. Além disso, as tendências obtidas fornecem um conhecimento mais claro da evolução desses fenômenos e dos cenários futuros, favorecendo a criação de planos de mitigação de impacto mais eficazes.

#### **4.4 Conclusões**

Os produtos SSEBop, GLEAM, PML e MME tiveram os melhores desempenhos com os maiores valores de correlação e concordância e menores erros no Pantanal.

O uso de MME possibilitou o estudo de áreas de micro e mesoescala, com a maior resolução espacial, o que gerou estimativas com maior detalhamento, sem afetar de tendências predominantes.

As estimativas de ET GPP no Cerrado e Pantanal tiveram tendência significativa de aumento em torno de 0,01mm e 0,05 gC m<sup>-2</sup>dia<sup>-1</sup> ao ano, respectivamente.

Os resultados forneceram um conhecimento mais claro de quais dados de ET e GPP são mais adequados para a região, como essas grandezas têm evoluído e quais os cenários futuros em relação a dinâmica dos fluxos de água e carbono no Mato Grosso.

## 5. CONCLUSÕES GERAIS

As estimativas de SM dos produtos CLSM-RZ, CLSM-S, NOAH10 e NOAH40 tiveram os melhores desempenhos, menores erros em áreas homogêneas.

Os produtos SSEBop, GLEAM, PML e MME tiveram os melhores desempenhos, especialmente no Pantanal, sendo de modo geral, apontados como as melhores alternativas para estimar a ET ou GPP em Mato Grosso.

O uso de MME possibilitou o estudo de áreas de micro e mesoescala, com a maior resolução espacial, o que gerou estimativas com maior detalhamento, sem afetar de tendências predominantes.

Os resultados forneceram um conhecimento mais claro de quais dados de ET e GPP são mais adequados para a região, como essas grandezas têm evoluído e quais os cenários futuros em relação a dinâmica dos fluxos de água e carbono no Mato Grosso.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

ABATZOGLOU, J. T.; DOBROWSKI, S. Z.; PARKS, S. A.; HEGEWISCH, K. C. TerraClimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958–2015. **Scientific Data**, [s. l.], v. 5, n. 1, p. 170191, 2018.

ALDRICH, S.; WALKER, R.; SIMMONS, C.; CALDAS, M.; PERZ, S. Contentious Land Change in the Amazon's Arc of Deforestation. **Annals of the Association of American Geographers**, [s. l.], v. 102, n. 1, p. 103–128, 2012.

ALLEN, R. G.; TASUMI, M.; TREZZA, R. Satellite-based energy balance for mapping evapotranspiration with internalized calibration (METRIC)—Model. **Journal of irrigation and drainage engineering**, [s. l.], v. 133, n. 4, p. 380–394, 2007.

ALLEN, R. G.; TASUMI, M.; TREZZA, R.; WATERS, R.; BASTIAANSEN, W. SEBAL (surface energy balance algorithms for land). **Advance training and users manual—Idaho implementation, version**, [s. l.], v. 1, p. 97, 2002.

ALTHOFF, D.; BAZAME, H. C.; FILGUEIRAS, R.; RODRIGUES, L. N. Assessing rainfall spatial variability in the Brazilian savanna region with TMPA rainfall dataset. **Journal of South American Earth Sciences**, [s. l.], v. 111, p. 103482, 2021a.

ALTHOFF, D.; RODRIGUES, L. N.; DA SILVA, D. D. Assessment of water availability vulnerability in the Cerrado. **Applied Water Science**, [s. l.], v. 11, n. 11, p. 176, 2021b.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; DE MORAES GONÇALVES, J. L.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, [s. l.], p. 711–728, 2013.

AMBROSONE, M.; MATESE, A.; DI GENNARO, S. F.; GIOLI, B.; TUDOROIU, M.; GENESIO, L.; MIGLIETTA, F.; BARONTI, S.; MAIENZA, A.; UNGARO, F.; TOSCANO, P. Retrieving soil moisture in rainfed and irrigated fields using Sentinel-2 observations and a modified OPTRAM approach. **International Journal of Applied Earth Observation and Geoinformation**, [s. l.], v. 89, p. 102113, 2020.

ANGELINI, L. P.; BIUDES, M. S.; MACHADO, N. G.; GELI, H. M. E.; VOURLITIS, G. L.; RUHOFF, A.; NOGUEIRA, J. de S. Surface Albedo and Temperature Models for Surface Energy Balance Fluxes and Evapotranspiration Using SEBAL and Landsat 8 over Cerrado-Pantanal, Brazil. **Sensors**, [s. l.], v. 21, n. 21, p. 7196, 2021.

ARAÚJO, A. A.; GARCIA, D. W.; MONTEIRO, J. R.; MIGUEL, T. V.; CAMPOS, B.; CARVALHO, V. S. B.; REBOITA, M. S. Avaliação do modelo Weather Research and Forecasting (WRF) na simulação operacional de um evento de frente fria no sudeste do Brasil. **Rev. Bras. Geogr. Fis.**, [s. l.], v. 16, p. 805–817, 2023.

ASNER, G. P. Cloud cover in Landsat observations of the Brazilian Amazon. **International Journal of Remote Sensing**, [s. l.], v. 22, n. 18, p. 3855–3862, 2001.

BAUR, M.; JAGDHUBER, T.; LINK, M.; PILES, M.; AKBAR, R.; ENTEKHABI, D. Multi-Frequency Estimation of Canopy Penetration Depths from SMAP/AMSR2 Radiometer and Icesat Lidar Data. *Em: IGARSS 2018 - 2018 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM*, 2018, [s. l.], . **Anais [...]**. [S. l.: s. n.], 2018. p. 365–368.

BEAUDOING, H. K.; RODELL, M. **GLDAS Noah Land Surface Model L4 3 hourly 0.25 x 0.25 degree V2.0 (GLDAS\_NOAH025\_3H 2.0)**. [S. l.: s. n.], 2019. Disponível em: [https://disc.gsfc.nasa.gov/datasets/GLDAS\\_NOAH025\\_3H\\_2.0/summary](https://disc.gsfc.nasa.gov/datasets/GLDAS_NOAH025_3H_2.0/summary). Acesso em: 20 abr. 2022.

BECK, H. E.; PAN, M.; MIRALLES, D. G.; REICHLER, R. H.; DORIGO, W. A.; HAHN, S.; SHEFFIELD, J.; KARTHIKEYAN, L.; BALSAMO, G.; PARINUSSA, R. M.; VAN DIJK, A. I. J. M.; DU, J.; KIMBALL, J. S.; VERGOPOLAN, N.; WOOD, E. F. Evaluation of 18 satellite- and model-based soil moisture products using in situ measurements from 826 sensors. **Hydrology and Earth System Sciences**, [s. l.], v. 25, n. 1, p. 17–40, 2021.

BEZERRA, E.; MAFALDA, S.; ALVAREZ, A. B.; UMAN-FLORES, D. A.; PEREZ-TORRES, W. I.; PALOMINO-QUISPE, F. A Cloud Coverage Image Reconstruction Approach for Remote Sensing of Temperature and Vegetation in Amazon Rainforest. **Applied Sciences**, [s. l.], v. 13, n. 23, p. 12900, 2023.

BEZERRA, B. G.; SANTOS, C. A. C. dos; SILVA, B. B. da; PEREZ-MARIN, A. M.; BEZERRA, M. V. C.; BEZERRA, J. R. C.; RAO, T. V. R. Estimation of soil moisture in the root-zone from remote sensing data. **Revista Brasileira de Ciência do Solo**, [s. l.], v. 37, p. 596–603, 2013.

BHAT, K. S.; HARAN, M.; TERANDO, A.; KELLER, K. Climate Projections Using Bayesian Model Averaging and Space–Time Dependence. **Journal of Agricultural, Biological, and Environmental Statistics**, [s. l.], v. 16, n. 4, p. 606–628, 2011.

BIUDES, M. S.; GELI, H. M. E.; VOURLITIS, G. L.; MACHADO, N. G.; PAVÃO, V. M.; DOS SANTOS, L. O. F.; QUERINO, C. A. S. Evapotranspiration Seasonality over Tropical Ecosystems in Mato Grosso, Brazil. **Remote Sensing**, [s. l.], v. 14, n. 10, p. 2482, 2022.

BIUDES, M. S.; VOURLITIS, G. L.; MACHADO, N. G.; DE ARRUDA, P. H. Z.; NEVES, G. A. R.; DE ALMEIDA LOBO, F.; NEALE, C. M. U.; DE SOUZA NOGUEIRA, J. Patterns of energy exchange for tropical ecosystems across a climate gradient in Mato Grosso, Brazil. **Agricultural and Forest Meteorology**, [s. l.], v. 202, p. 112–124, 2015.

BIUDES, M. S.; VOURLITIS, G. L.; VELASQUE, M. C. S.; MACHADO, N. G.; DANELICHEN, V. H. de M.; PAVÃO, V. M.; ARRUDA, P. H. Z.; NOGUEIRA, J. de S. Gross primary productivity of Brazilian Savanna (Cerrado) estimated by different remote sensing-based models. **Agricultural and Forest Meteorology**, [s. l.], v. 307, p. 108456, 2021.

BONAN, G. B.; LAWRENCE, P. J.; OLESON, K. W.; LEVIS, S.; JUNG, M.; REICHSTEIN, M.; LAWRENCE, D. M.; SWENSON, S. C. Improving canopy processes in the Community Land Model version 4 (CLM4) using global flux fields empirically inferred from FLUXNET data. **Journal of Geophysical Research: Biogeosciences**, [s. l.], v. 116, n. G2, 2011. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1029/2010JG001593>. Acesso em: 20 maio 2024.

BORSATO, V. da A.; MENDONÇA, F. de A. PARTICIPAÇÃO DA MASSA POLAR ATLÂNTICA NA DINÂMICA DOS SISTEMAS ATMOSFÉRICOS NO CENTRO SUL DO BRASIL. **Mercator (Fortaleza)**, [s. l.], v. 14, p. 113–130, 2015.

BROCCA, L.; CROW, W. T.; CIABATTA, L.; MASSARI, C.; DE ROSNAY, P.; ENENKEL, M.; HAHN, S.; AMARNATH, G.; CAMICI, S.; TARPANELLI, A.; WAGNER, W. A Review of the Applications of ASCAT Soil Moisture Products. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [s. l.], v. 10, n. 5, p. 2285–2306, 2017.

BUENO, P. **Período úmido: os principais sistemas meteorológicos da estação chuvosa** Período úmido. [S. l.: s. n.], 2022. Disponível em: <https://www.tempo.com/noticias/ciencia/periodo-umido-os-principais-sistemas-meteorologicos-da-estacao-chuvosa-clima-primavera.html>. Acesso em: 28 out. 2024.

BURDUN, I.; BECHTOLD, M.; SAGRIS, V.; KOMISARENKO, V.; DE LANNOY, G.; MANDER, Ü. A Comparison of Three Trapezoid Models Using Optical and Thermal Satellite Imagery for Water Table Depth Monitoring in Estonian Bogs. **Remote Sensing**, [s. l.], v. 12, n. 12, p. 1980, 2020.

CARLSON, T. An Overview of the “Triangle Method” for Estimating Surface Evapotranspiration and Soil Moisture from Satellite Imagery. **Sensors**, [s. l.], v. 7, n. 8, p. 1612–1629, 2007.

CHANDLER, R. E. Exploiting strength, discounting weakness: combining information from multiple climate simulators. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, [s. l.], v. 371, n. 1991, p. 20120388, 2013.

CHEN, Hui; CHEN, Hongxing; ZHANG, S.; CHEN, S.; CEN, F.; ZHAO, Q.; HUANG, X.; HE, T.; GAO, Z. Comparison of CWSI and  $T_s-T_a$ -VIs in moisture monitoring of dryland crops (sorghum, maize) based on UAV remote sensing. **Journal of Integrative Agriculture**, [s. l.], 2024. Disponível em: <https://www.sciencedirect.com/science/article/pii/S209531192400114X>. Acesso em: 23 mar. 2024.

CHENG, M.; YIN, D.; WU, W.; CUI, N.; NIE, C.; SHI, L.; LIU, S.; YU, X.; BAI, Y.; LIU, Y.; ZHU, Y.; JIN, X. A review of remote sensing estimation of crop water productivity: definition, methodology, scale, and evaluation. **International Journal of Remote Sensing**, [s. l.], v. 44, n. 16, p. 5033–5068, 2023.

CHRISTIANSEN, B. Ensemble Averaging and the Curse of Dimensionality. **Journal of Climate**, [s. l.], v. 31, n. 4, p. 1587–1596, 2018.

COLLIANDER, A.; JACKSON, T. J.; BINDLISH, R.; CHAN, S.; DAS, N.; KIM, S. B.; COSH, M. H.; DUNBAR, R. S.; DANG, L.; PASHAIAN, L.; ASANUMA, J.; AIDA, K.; BERG, A.; ROWLANDSON, T.; BOSCH, D.; CALDWELL, T.; CAYLOR, K.; GOODRICH, D.; AL JASSAR, H.; LOPEZ-BAEZA, E.; MARTÍNEZ-FERNÁNDEZ, J.; GONZÁLEZ-ZAMORA, A.; LIVINGSTON, S.; MCNAIRN, H.; PACHECO, A.; MOGHADDAM, M.; MONTZKA, C.; NOTARNICOLA, C.; NIEDRIST, G.; PELLARIN, T.; PRUEGER, J.; PULLIAINEN, J.; RAUTIAINEN, K.; RAMOS, J.; SEYFRIED, M.; STARKS, P.; SU, Z.; ZENG, Y.; VAN DER VELDE, R.; THIBEAULT, M.; DORIGO, W.; VREUGDENHIL, M.; WALKER, J. P.; WU, X.; MONERRIS, A.; O'NEILL, P. E.; ENTEKHABI, D.; NJOKU, E. G.; YUEH, S. Validation of SMAP surface soil moisture products with core validation sites. **Remote Sensing of Environment**, [s. l.], v. 191, p. 215–231, 2017.

DA SILVA ARRUDA, V. L.; ALENCAR, A. A. C.; DE CARVALHO JÚNIOR, O. A.; DE FIGUEIREDO RIBEIRO, F.; DE ARRUDA, F. V.; CONCIANI, D. E.; DA SILVA, W. V.; SHIMBO, J. Z. Assessing four decades of fire behavior dynamics in the Cerrado biome (1985 to 2022). **Fire Ecology**, [s. l.], v. 20, n. 1, p. 64, 2024.

DAIREL, M.; FIDELIS, A. Fire stimulates seedling recruitment from the seed bank in the Cerrado. **Journal of Vegetation Science**, [s. l.], v. 35, n. 3, p. e13268, 2024.

DANELICHEN, V. H. de M.; BIUDES, M. S. Biophysical parameters analysis in the detection of coverage changes and land use in a conservation unit in the Brazilian Pantanal. **Revista Ibero-Americana de Ciências Ambientais**, [s. l.], v. 11, n. 5, p. 664–676, 2020.

DANELICHEN, V. H. de M.; BIUDES, M. S.; SOUZA, M. C.; MACHADO, N. G.; NOGUEIRA, J. de S. Relations of vegetation and water indices to volumetric soil water content in the Pantanal of Mato Grosso, Brazil. **International Journal of Remote Sensing**, [s. l.], v. 37, n. 18, p. 4261–4275, 2016.

DAS, B.; RATHORE, P.; ROY, D.; CHAKRABORTY, D.; BHATTACHARYA, B. K.; MANDAL, D.; JATAV, R.; SETHI, D.; MUKHERJEE, J.; SEHGAL, V. K.; SINGH, A. K.; KUMAR, P. Ensemble surface soil moisture estimates at farm-scale combining satellite-based optical-thermal-microwave remote sensing observations. **Agricultural and Forest Meteorology**, [s. l.], v. 339, p. 109567, 2023.

DE ABREU, M. L. Climatologia da estação chuvosa de Minas Gerais: de Nimer (1977) à Zona de Convergência do Atlântico Sul. **Geonomos**, [s. l.], 1998.

DE OLIVEIRA, G.; BRUNSELL, N. A.; MORAES, E. C.; BERTANI, G.; DOS SANTOS, T. V.; SHIMABUKURO, Y. E.; ARAGÃO, L. E. O. C. Use of MODIS Sensor Images Combined with Reanalysis Products to Retrieve Net Radiation in Amazonia. **Sensors**, [s. l.], v. 16, n. 7, p. 956, 2016.

DEGANO, M. F.; RIVAS, R. E.; CARMONA, F.; NICLÒS, R.; SÁNCHEZ, J. M. Evaluation of the MOD16A2 evapotranspiration product in an agricultural area of Argentina, the Pampas region. **The Egyptian Journal of Remote Sensing and Space Science**, [s. l.], v. 24, n. 2, p. 319–328, 2021.

DENTE, L.; SU, Z.; WEN, J. Validation of SMOS Soil Moisture Products over the Maqu and Twente Regions. **Sensors**, [s. l.], v. 12, n. 8, p. 9965–9986, 2012.

DHARUMARAJAN, S.; LALITHA, M.; KALAISELVI, B.; KALIRAJ, S.; ADHIKARI, K.; VASUNDHARA, R.; NIRANJANA, K. V.; HEGDE, R.; PRADEEP, C. M.; HITTANAGI, P.; RAMAMURTHY, V. Chapter 2 - Remote sensing of soils: spectral signatures and spectral indices. *Em*: DHARUMARAJAN, S.; KALIRAJ, S.; ADHIKARI, K.; LALITHA, M.; KUMAR, N. (org.). **Remote Sensing of Soils**. [S. l.]: Elsevier, 2024. p. 13–23. Disponível em: <https://www.sciencedirect.com/science/article/pii/B9780443187735000338>. Acesso em: 13 mar. 2024.

DIAS LOPES, J.; NEIVA RODRIGUES, L.; ACIOLI IMBUZEIRO, H. M.; FALCO PRUSKI, F. Performance of SSEBop model for estimating wheat actual evapotranspiration in the Brazilian Savannah region. **International Journal of Remote Sensing**, [s. l.], v. 40, n. 18, p. 6930–6947, 2019.

DIAS, P. L. S.; SCHUBERT, W. H.; DEMARIA, M. Large-Scale Response of the Tropical Atmosphere to Transient Convection. **Journal of the Atmospheric Sciences**, [s. l.], v. 40, n. 11, p. 2689–2707, 1983.

DONG, Q.; ZHAN, C.; WANG, H.; WANG, F.; ZHU, M. A review on evapotranspiration data assimilation based on hydrological models. **Journal of Geographical Sciences**, [s. l.], v. 26, n. 2, p. 230–242, 2016.

DORIGO, W.; WAGNER, W.; ALBERGEL, C.; ALBRECHT, F.; BALSAMO, G.; BROCCA, L.; CHUNG, D.; ERTL, M.; FORKEL, M.; GRUBER, A.; HAAS, E.; HAMER, P. D.; HIRSCHI, M.; IKONEN, J.; DE JEU, R.; KIDD, R.; LAHOZ, W.; LIU, Y. Y.; MIRALLES, D.; MISTELBAUER, T.; NICOLAI-SHAW, N.; PARINUSSA, R.; PRATOLA, C.; REIMER, C.; VAN DER SCHALIE, R.; SENEVIRATNE, S. I.; SMOLANDER, T.; LECOMTE, P. ESA CCI Soil Moisture for improved Earth system understanding: State-of-the art and future directions. **Remote Sensing of Environment**, [s. l.], v. 203, Earth Observation of Essential Climate Variables, p. 185–215, 2017.

DOS SANTOS, L. O. F.; MACHADO, N. G.; BIUDES, M. S.; GELI, H. M. E.; QUERINO, C. A. S.; RUHOFF, A. L.; IVO, I. O.; LOTUFO NETO, N. Trends in Precipitation and Air Temperature Extremes and Their Relationship with Sea Surface Temperature in the Brazilian Midwest. **Atmosphere**, [s. l.], v. 14, n. 3, p. 426, 2023.

DUAN, Q.; AJAMI, N. K.; GAO, X.; SOROOSHIAN, S. Multi-model ensemble hydrologic prediction using Bayesian model averaging. **Advances in Water Resources**, [s. l.], v. 30, n. 5, p. 1371–1386, 2007.

DUARTE, L. G.; ROMERA, K. S.; SABINO, M.; CURADO, L. F. A.; DA SILVA PALÁCIOS, R.; DE SOUZA NOGUEIRA, J. DYNAMICS OF HEAT FLUXES BY BOWEN AND MATMNXFLX AND NOAH FLDAS PRODUCTS IN THE PANTANAL OF MATO GROSSO. **Raega-O Espaço Geográfico em Análise**, [s. l.], v. 46, n. 3, p. 07–19, 2019.

DUBEY, S. K.; LAL, P.; CHOUDHARI, P.; SHARMA, A.; DUBEY, A. K. Chapter 11 - Assessment of long-term groundwater variation in India using GLDAS reanalysis. *Em*: GUPTA, Pankaj Kumar; YADAV, Basant; HIMANSHU, Sushil Kumar (org.). **Advances in Remediation Techniques for Polluted Soils and Groundwater**. [S. l.]: Elsevier, 2022. p. 219–232. Disponível em: <https://www.sciencedirect.com/science/article/pii/B9780128238301000183>.

EL HAJJ, M.; BAGHDADI, N.; ZRIBI, M.; RODRÍGUEZ-FERNÁNDEZ, N.; WIGNERON, J. P.; AL-YAARI, A.; AL BITAR, A.; ALBERGEL, C.; CALVET, J.-C. Evaluation of SMOS, SMAP, ASCAT and Sentinel-1 Soil Moisture Products at Sites in Southwestern France. **Remote Sensing**, [s. l.], v. 10, n. 4, p. 569, 2018.

ELNASHAR, A.; WANG, L.; WU, B.; ZHU, W.; ZENG, H. Synthesis of global actual evapotranspiration from 1982 to 2019. **Earth System Science Data**, [s. l.], v. 13, n. 2, p. 447–480, 2021.

EMBRAPA. **WebGIS TerraClass**. [S. l.: s. n.], 2018. Disponível em: <https://www.terraclass.gov.br/webgis-cerrado/#>. Acesso em: 7 mar. 2022.

ENTEKHABI, D.; NJOKU, E. G.; O'NEILL, P. E.; KELLOGG, K. H.; CROW, W. T.; EDELSTEIN, W. N.; ENTIN, J. K.; GOODMAN, S. D.; JACKSON, T. J.; JOHNSON, J.; KIMBALL, J.; PIEPMEIER, J. R.; KOSTER, R. D.; MARTIN, N.; MCDONALD, K. C.; MOGHADDAM, M.; MORAN, S.; REICHLE, R.; SHI, J. C.; SPENCER, M. W.; THURMAN, S. W.; TSANG, L.; VAN ZYL, J. The Soil Moisture Active Passive (SMAP) Mission. **Proceedings of the IEEE**, [s. l.], v. 98, n. 5, p. 704–716, 2010.

ESCOBAR, G. C. J. Padrões de circulação em superfície e em 500 hPa na América do Sul e eventos de anomalias positivas de precipitação no estado de Minas Gerais durante o mês de dezembro de 2011. **Revista Brasileira de Meteorologia**, [s. l.], v. 29, p. 105–124, 2014.

ESCOBAR, G. C. J.; REBOITA, M. S.; ESCOBAR, G. C. J.; REBOITA, M. S. Relationship between daily atmospheric circulation patterns and South Atlantic Convergence Zone (SACZ) events. **Atmosfera**, [s. l.], v. 35, n. 1, p. 1–25, 2022.

ESPINOZA, J. C.; LENGAINNE, M.; RONCHAIL, J.; JANICOT, S. Large-scale circulation patterns and related rainfall in the Amazon Basin: a neuronal networks approach. **Climate Dynamics**, [s. l.], v. 38, n. 1, p. 121–140, 2012.

FANG, B.; KANSARA, P.; DANDRIDGE, C.; LAKSHMI, V. Drought monitoring using high spatial resolution soil moisture data over Australia in 2015–2019. **Journal of Hydrology**, [s. l.], v. 594, p. 125960, 2021.

FANG, B.; LAKSHMI, V.; BINDLISH, R.; JACKSON, T. J.; COSH, M.; BASARA, J. Passive Microwave Soil Moisture Downscaling Using Vegetation Index and Skin Surface Temperature. **Vadose Zone Journal**, [s. l.], v. 12, n. 3, p. vztj2013.05.0089, 2013.

FANG, B.; LAKSHMI, V.; ZHANG, R. Validation of downscaled 1-km SMOS and SMAP soil moisture data in 2010–2021. **Vadose Zone Journal**, [s. l.], v. 23, n. 2, p. e20305, 2024.

FAUSTO, M. A.; MACHADO, N. G.; NOGUEIRA, J. de S.; BIUDES, M. S. Net radiation estimated by remote sensing in Cerrado areas in the Upper Paraguay River Basin. **Journal of Applied Remote Sensing**, [s. l.], v. 8, n. 1, p. 083541, 2014.

FERRARINI, A. dos S. F.; FERREIRA FILHO, J. B. de S.; CUADRA, S. V.; VICTORIA, D. de C.; HORRIDGE, M. The Expansion of Irrigated Agriculture in Brazil and Potential Regional Limitations. *Em: WITTEWER, Glyn (org.). Economy-Wide Modeling of Water at Regional and Global Scales*. Singapore: Springer, 2019. (modelagem de equilíbrio geral aplicado). p. 139–157. Disponível em: [https://doi.org/10.1007/978-981-13-6101-2\\_7](https://doi.org/10.1007/978-981-13-6101-2_7). Acesso em: 7 mar. 2022.

FERREIRA, J.; PARDINI, R.; METZGER, J. P.; FONSECA, C. R.; POMPEU, P. S.; SPAROVEK, G.; LOUZADA, J. Towards environmentally sustainable agriculture in Brazil: challenges and opportunities for applied ecological research. **Journal of Applied Ecology**, [s. l.], v. 49, n. 3, p. 535–541, 2012.

FILION, R.; BERNIER, M.; PANICONI, C.; CHOKMANI, K.; MELIS, M.; SODDU, A.; TALAZAC, M.; LAFORTUNE, F.-X. Remote sensing for mapping soil moisture and drainage potential in semi-arid regions: Applications to the Campidano plain of Sardinia, Italy. **Science of The Total Environment**, [s. l.], v. 543, Special Issue on Climate Change, Water and Security in the Mediterranean, p. 862–876, 2016.

FURQUIM, L. C.; SANTOS, M. P. dos; ANDRADE, C. A. O. de; OLIVEIRA, L. A. de; EVANGELISTA, A. W. P. Relação entre plantas nativas do Cerrado e água. **Científic@ - Multidisciplinary Journal**, [s. l.], v. 5, n. 2, p. 146–156, 2018.

GARCÍA-SANTOS, V.; SÁNCHEZ, J. M.; CUXART, J. Evapotranspiration Acquired with Remote Sensing Thermal-Based Algorithms: A State-of-the-Art Review. **Remote Sensing**, [s. l.], v. 14, n. 14, p. 3440, 2022.

GELYBÓ, Gy.; BARCZA, Z.; KERN, A.; KLJUN, N. Effect of spatial heterogeneity on the validation of remote sensing based GPP estimations. **Agricultural and Forest Meteorology**, [s. l.], v. 174–175, p. 43–53, 2013.

GILLETT, N. P.; ZWIERS, F. W.; WEAVER, A. J.; HEGERL, G. C.; ALLEN, M. R.; STOTT, P. A. Detecting anthropogenic influence with a multi-model ensemble. **Geophysical Research Letters**, [s. l.], v. 29, n. 20, p. 31-1-31–4, 2002.

GLATZLE, S.; DE ALMEIDA, R. G.; PEREIRA BARSOTTI, M.; BUNGENSTAB, D. J.; GIESE, M.; MACEDO, M. C. M.; STUERZ, S.; ASCH, F. Integrated Land-Use

Systems Contribute to Restoring Water Cycles in the Brazilian Cerrado Biome. **Land**, [s. l.], v. 13, n. 2, p. 221, 2024.

GLATZLE, S.; STUERZ, S.; GIESE, M.; PEREIRA, M.; DE ALMEIDA, R. G.; BUNGENSTAB, D. J.; MACEDO, M. C. M.; ASCH, F. Seasonal Dynamics of Soil Moisture in an Integrated-Crop-Livestock-Forestry System in Central-West Brazil. **Agriculture**, [s. l.], v. 11, n. 3, p. 245, 2021.

GONÇALVES, I. Z.; RUHOFF, A.; LAIPELT, L.; BISPO, R. C.; HERNANDEZ, F. B. T.; NEALE, C. M. U.; TEIXEIRA, A. H. C.; MARIN, F. R. Remote sensing-based evapotranspiration modeling using geeSEBAL for sugarcane irrigation management in Brazil. **Agricultural Water Management**, [s. l.], v. 274, p. 107965, 2022.

GONZÁLEZ-ESTRADA, E.; COSMES, W. Shapiro–Wilk test for skew normal distributions based on data transformations. **Journal of Statistical Computation and Simulation**, [s. l.], v. 89, n. 17, p. 3258–3272, 2019.

GOOD, P. I. **Resampling methods**. [S. l.]: Springer, 2006. 2006.

GRUBER, A.; SCANLON, T.; VAN DER SCHALIE, R.; WAGNER, W.; DORIGO, W. Evolution of the ESA CCI Soil Moisture climate data records and their underlying merging methodology. **Earth System Science Data**, [s. l.], v. 11, n. 2, p. 717–739, 2019.

GUO, Z.; DIRMEYER, P. A.; GAO, X.; ZHAO, M. Improving the quality of simulated soil moisture with a multi-model ensemble approach. **Quarterly Journal of the Royal Meteorological Society**, [s. l.], v. 133, n. 624, p. 731–747, 2007.

H SAF. **EUMETSAT - Product Navigator - ASCAT Surface Soil Moisture Climate Data Record v5 12.5 km sampling - Metop**. [S. l.: s. n.], 2020. Disponível em: <https://navigator.eumetsat.int/product/EO:EUM:DAT:0307>. Acesso em: 8 mar. 2022.

HAMED, K. H.; RAMACHANDRA RAO, A. A modified Mann-Kendall trend test for autocorrelated data. **Journal of Hydrology**, [s. l.], v. 204, n. 1, p. 182–196, 1998.

HARIDASAN, M. Nutritional adaptations of native plants of the cerrado biome in acid soils. **Brazilian Journal of Plant Physiology**, [s. l.], v. 20, p. 183–195, 2008.

HAZRA, A.; MCNALLY, A.; SLINSKI, K.; ARSENAULT, K. R.; SHUKLA, S.; GETIRANA, A.; JACOB, J. P.; SARMIENTO, D. P.; PETERS-LIDARD, C.; KUMAR, S. V.; KOSTER, R. D. NASA's NMME-based S2S hydrologic forecast system for food insecurity early warning in southern Africa. **Journal of Hydrology**, [s. l.], v. 617, p. 129005, 2023.

HE, M.; KIMBALL, J. S.; YI, Y.; RUNNING, S. W.; GUAN, K.; MORENO, A.; WU, X.; MANETA, M. Satellite data-driven modeling of field scale evapotranspiration in croplands using the MOD16 algorithm framework. **Remote Sensing of Environment**, [s. l.], v. 230, p. 111201, 2019.

HERSBACH, H.; BELL, B.; BERRISFORD, P.; HIRAHARA, S.; HORÁNYI, A.; MUÑOZ-SABATER, J.; NICOLAS, J.; PEUBEY, C.; RADU, R.; SCHEPERS, D.; SIMMONS, A.; SOCI, C.; ABDALLA, S.; ABELLAN, X.; BALSAMO, G.; BECHTOLD, P.; BIAVATI, G.; BIDLOT, J.; BONAVIDA, M.; DE CHIARA, G.; DAHLGREN, P.; DEE, D.; DIAMANTAKIS, M.; DRAGANI, R.; FLEMMING, J.; FORBES, R.; FUENTES, M.; GEER, A.; HAIMBERGER, L.; HEALY, S.; HOGAN, R. J.; HÓLM, E.; JANISKOVÁ, M.; KEELEY, S.; LALOYAUX, P.; LOPEZ, P.; LUPU, C.; RADNOTI, G.; DE ROSNAY, P.; ROZUM, I.; VAMBORG, F.; VILLAUME, S.; THÉPAUT, J.-N. The ERA5 global reanalysis. **Quarterly Journal of the Royal Meteorological Society**, [s. l.], v. 146, n. 730, p. 1999–2049, 2020.

HODSON, T. O. Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. **Geoscientific Model Development**, [s. l.], v. 15, n. 14, p. 5481–5487, 2022.

HU, K. X.; AWANGE, J. L.; KUHN, M.; NANTEZA, J. Inference of the spatio-temporal variability and storage potential of groundwater in data-deficient regions through groundwater models and inversion of impact factors on groundwater, as exemplified by the Lake Victoria Basin. **Science of The Total Environment**, [s. l.], v. 800, p. 149355, 2021.

IBGE. **Biomás** | **IBGE**. [S. l.: s. n.], 2024. Disponível em: <https://www.ibge.gov.br/geociencias/informacoes-ambientais/estudos-ambientais/15842-biomas.html?=&t=o-que-e>. Acesso em: 7 mar. 2022.

IPCC. Evaluation of Climate Models. *Em*: CLIMATE CHANGE 2013 – THE PHYSICAL SCIENCE BASIS: WORKING GROUP I CONTRIBUTION TO THE FIFTH ASSESSMENT REPORT OF THE INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. Cambridge: Cambridge University Press, 2014. p. 741–866. Disponível em: <https://www.cambridge.org/core/books/climate-change-2013-the-physical-science-basis/evaluation-of-climate-models/94BC2268C864F2C6A18436DB22BD1E5A>.

JACKSON, T. J.; SCHMUGGE, T. J. Vegetation effects on the microwave emission of soils. **Remote Sensing of Environment**, [s. l.], v. 36, n. 3, p. 203–212, 1991.

JAIN, A. K.; TAO, Z.; YANG, X.; GILLESPIE, C. Estimates of global biomass burning emissions for reactive greenhouse gases (CO, NMHCs, and NO<sub>x</sub>) and CO<sub>2</sub>. **Journal of Geophysical Research: Atmospheres**, [s. l.], v. 111, n. D6, 2006. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1029/2005JD006237>. Acesso em: 25 maio 2024.

JAIN, A.; YANG, X.; KHESHGI, H.; MCGUIRE, A. D.; POST, W.; KICKLIGHTER, D. Nitrogen attenuation of terrestrial carbon cycle response to global environmental factors. **Global Biogeochemical Cycles**, [s. l.], v. 23, n. 4, 2009. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1029/2009GB003519>. Acesso em: 16 maio 2024.

JIANG, Q.; LI, W.; FAN, Z.; HE, X.; SUN, W.; CHEN, S.; WEN, J.; GAO, J.; WANG, J. Evaluation of the ERA5 reanalysis precipitation dataset over Chinese Mainland. **Journal of Hydrology**, [s. l.], v. 595, p. 125660, 2021.

JIANG, Y.; TANG, R.; JIANG, X.; LI, Z.-L.; GAO, C. Estimation of Soil Evaporation and Vegetation Transpiration Using Two Trapezoidal Models From MODIS Data. **Journal of Geophysical Research: Atmospheres**, [s. l.], v. 124, n. 14, p. 7647–7664, 2019.

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. Assessment of Remote Sensing and Re-Analysis Estimates of Regional Precipitation over Mato Grosso, Brazil. **Water**, [s. l.], v. 13, n. 3, p. 333, 2021.

KE, Y.; IM, J.; LEE, J.; GONG, H.; RYU, Y. Characteristics of Landsat 8 OLI-derived NDVI by comparison with multiple satellite sensors and in-situ observations. **Remote Sensing of Environment**, [s. l.], v. 164, p. 298–313, 2015.

KERR, Y. H.; WALDTEUFEL, P.; RICHAUME, P.; WIGNERON, J. P.; FERRAZZOLI, P.; MAHMOODI, A.; AL BITAR, A.; CABOT, F.; GRUHIER, C.; JUGLEA, S. E.; LEROUX, D.; MIALON, A.; DELWART, S. The SMOS Soil Moisture Retrieval Algorithm. **IEEE Transactions on Geoscience and Remote Sensing**, [s. l.], v. 50, n. 5, p. 1384–1403, 2012.

KHAKI, M.; AWANGE, J.; FOROOTAN, E.; KUHN, M. Understanding the association between climate variability and the Nile's water level fluctuations and water storage changes during 1992–2016. **Science of The Total Environment**, [s. l.], v. 645, p. 1509–1521, 2018.

KIM, D.; BAIK, J.; UMAIR, M.; CHOI, M. Water use efficiency in terrestrial ecosystem over East Asia: Effects of climate regimes and land cover types. **Science of The Total Environment**, [s. l.], v. 773, p. 145519, 2021.

KIOUTSIUKIS, I.; GALMARINI, S. *De praeceptis ferendis*: good practice in multi-model ensembles. **Atmospheric Chemistry and Physics**, [s. l.], v. 14, n. 21, p. 11791–11815, 2014.

KÖPPEN, W.; GEIGER, R. **Handbuch der klimatologie**. [S. l.]: Gebrüder Borntraeger Berlin, 1930. 1930.v. 1.

KOZAK, M. What is Strong Correlation?. **Teaching Statistics**, [s. l.], v. 31, n. 3, p. 85–86, 2009.

KUSCHNIG, N.; CUARESMA, J. C.; KRISZTIN, T.; GILJUM, S. Spatial spillover effects from agriculture drive deforestation in Mato Grosso, Brazil. **Scientific Reports**, [s. l.], v. 11, n. 1, p. 21804, 2021.

LAIPELT, L.; HENRIQUE BLOEDOW KAYSER, R.; SANTOS FLEISCHMANN, A.; RUHOFF, A.; BASTIAANSEN, W.; ERICKSON, T. A.; MELTON, F. Long-term monitoring of evapotranspiration using the SEBAL algorithm and Google Earth

Engine cloud computing. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s. l.], v. 178, p. 81–96, 2021.

LAMBIN, E. F.; EHRLICH, D. The surface temperature-vegetation index space for land cover and land-cover change analysis. **International Journal of Remote Sensing**, [s. l.], v. 17, n. 3, p. 463–487, 1996.

LATHUILLIÈRE, M. J.; JOHNSON, M. S.; DONNER, S. D. Water use by terrestrial ecosystems: temporal variability in rainforest and agricultural contributions to evapotranspiration in Mato Grosso, Brazil. **Environmental Research Letters**, [s. l.], v. 7, n. 2, p. 024024, 2012.

LENG, P.; SONG, X.; LI, Z.-L.; MA, J.; ZHOU, F.; LI, S. Bare surface soil moisture retrieval from the synergistic use of optical and thermal infrared data. **International Journal of Remote Sensing**, [s. l.], v. 35, n. 3, p. 988–1003, 2014.

LEUNING, R.; ZHANG, Y. Q.; RAJAUD, A.; CLEUGH, H.; TU, K. A simple surface conductance model to estimate regional evaporation using MODIS leaf area index and the Penman-Monteith equation. **Water Resources Research**, [s. l.], v. 44, n. 10, 2008. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1029/2007WR006562>. Acesso em: 4 out. 2023.

LI, B.; RODELL, M.; KUMAR, S.; BEAUDOING, H. K.; GETIRANA, A.; ZAITCHIK, B. F.; DE GONCALVES, L. G.; COSSETIN, C.; BHANJA, S.; MUKHERJEE, A.; TIAN, S.; TANGDAMRONGSUB, N.; LONG, D.; NANTEZA, J.; LEE, J.; POLICELLI, F.; GONI, I. B.; DAIRA, D.; BILA, M.; DE LANNOY, G.; MOCKO, D.; STEELE-DUNNE, S. C.; SAVE, H.; BETTADPUR, S. Global GRACE Data Assimilation for Groundwater and Drought Monitoring: Advances and Challenges. **Water Resources Research**, [s. l.], v. 55, n. 9, p. 7564–7586, 2019.

LI, Z.-L.; TANG, R.; WAN, Z.; BI, Y.; ZHOU, C.; TANG, B.; YAN, G.; ZHANG, X. A Review of Current Methodologies for Regional Evapotranspiration Estimation from Remotely Sensed Data. **Sensors**, [s. l.], v. 9, n. 5, p. 3801–3853, 2009.

LIOU, Y.-A.; KAR, S. K. Evapotranspiration Estimation with Remote Sensing and Various Surface Energy Balance Algorithms—A Review. **Energies**, [s. l.], v. 7, n. 5, p. 2821–2849, 2014.

LIU, X.; CHEN, F.; BARLAGE, M.; NIYOGI, D. Implementing Dynamic Rooting Depth for Improved Simulation of Soil Moisture and Land Surface Feedbacks in Noah-MP-Crop. **Journal of Advances in Modeling Earth Systems**, [s. l.], v. 12, n. 2, p. e2019MS001786, 2020.

LUO, L.; WOOD, E. F. Use of Bayesian Merging Techniques in a Multimodel Seasonal Hydrologic Ensemble Prediction System for the Eastern United States. **Journal of Hydrometeorology**, [s. l.], v. 9, n. 5, p. 866–884, 2008.

MA, Y.; SUN, S.; LI, C.; ZHAO, J.; LI, Z.; JIA, C. Estimation of regional actual evapotranspiration based on the improved SEBAL model. **Journal of Hydrology**, [s. l.], v. 619, p. 129283, 2023.

MACHADO, N. G.; BIUDES, M. S.; ANGELINI, L. P.; MÜTZENBERG, D. M. de S.; NASSARDEN, D. C. S.; BILIO, R. de S.; SILVA, T. J. A. da; NEVES, G. A. R.; ARRUDA, P. H. Z. de; NOGUEIRA, J. de S. Sazonalidade do Balanço de Energia e Evapotranspiração em Área Arbustiva Alagável no Pantanal Mato-Grossense. **Revista Brasileira de Meteorologia**, [s. l.], v. 31, p. 82–91, 2016.

MACHADO, N. G.; BIUDES, M. S.; ANGELINI, L. P.; QUERINO, C. A. S.; DA SILVA ANGELINI, P. C. B. Impact of changes in surface cover on energy balance in a tropical city by remote sensing: A study case in Brazil. **Remote Sensing Applications: Society and Environment**, [s. l.], v. 20, p. 100373, 2020.

MACHADO, N. G.; BIUDES, M. S.; QUERINO, C. A. S.; DANELICHEN, V. H. de M.; VELASQUE, M. C. S. SEASONAL AND INTERANNUAL PATTERN OF METEOROLOGICAL VARIABLES IN CUIABÁ• , MATO GROSSO STATE, BRAZIL. **Brazilian Journal of Geophysics**, [s. l.], v. 33, n. 3, p. 477–488, 2015.

MARACAHIPES-SANTOS, L.; LENZA, E.; SANTOS, J. O.; MEWS, H. A.; OLIVEIRA, B. Effects of soil and space on the woody species composition and vegetation structure of three Cerrado phytogeographies in the Cerrado-Amazon transition. **Brazilian Journal of Biology**, [s. l.], v. 77, p. 830–839, 2017.

MARQUES, J. F.; ALVES, M. B.; SILVEIRA, C. F.; AMARAL E SILVA, A.; SILVA, T. A.; DOS SANTOS, V. J.; CALIJURI, M. L. Fires dynamics in the Pantanal: Impacts of anthropogenic activities and climate change. **Journal of Environmental Management**, [s. l.], v. 299, p. 113586, 2021.

MARQUES, E. Q.; MARIMON-JUNIOR, B. H.; MARIMON, B. S.; MATRICARDI, E. A. T.; MEWS, H. A.; COLLI, G. R. Redefining the Cerrado–Amazonia transition: implications for conservation. **Biodiversity and Conservation**, [s. l.], v. 29, n. 5, p. 1501–1517, 2020.

MARTENS, B.; MIRALLES, D. G.; LIEVENS, H.; VAN DER SCHALIE, R.; DE JEU, R. A. M.; FERNÁNDEZ-PRÍETO, D.; BECK, H. E.; DORIGO, W. A.; VERHOEST, N. E. C. GLEAM v3: satellite-based land evaporation and root-zone soil moisture. **Geoscientific Model Development**, [s. l.], v. 10, n. 5, p. 1903–1925, 2017.

MCLEOD, A. I. Kendall rank correlation and Mann-Kendall trend test. **R package Kendall**, [s. l.], v. 602, p. 1–10, 2005.

MCNALLY, A. FLDAS noah land surface model L4 global monthly 0.1×0.1 degree (MERRA-2 and CHIRPS). **Atmos. Compos. Water Energy Cycles Clim. Var**, [s. l.], 2018.

MCNALLY, A.; ARSENAULT, K.; KUMAR, S.; SHUKLA, S.; PETERSON, P.; WANG, S.; FUNK, C.; PETERS-LIDARD, C. D.; VERDIN, J. P. A land data

assimilation system for sub-Saharan Africa food and water security applications. **Scientific Data**, [s. l.], v. 4, n. 1, p. 170012, 2017.

MCNALLY, A.; JACOB, J.; ARSENAULT, K.; SLINSKI, K.; SARMIENTO, D. P.; HOELL, A.; PERVEZ, S.; ROWLAND, J.; BUDDE, M.; KUMAR, S.; PETERS-LIDARD, C.; VERDIN, J. P. A Central Asia hydrologic monitoring dataset for food and water security applications in Afghanistan. **Earth System Science Data**, [s. l.], v. 14, n. 7, p. 3115–3135, 2022.

MENENTI, M.; CHOUDHURY, B. Parameterization of land surface evaporation by means of location dependent potential evaporation and surface temperature range. [s. l.], 1993.

MINACAPILLI, M.; AGNESE, C.; BLANDA, F.; CAMMALLERI, C.; CIRAOLO, G.; D'URSO, G.; IOVINO, M.; PUMO, D.; PROVENZANO, G.; RALLO, G. Estimation of actual evapotranspiration of Mediterranean perennial crops by means of remote-sensing based surface energy balance models. **Hydrology and Earth System Sciences**, [s. l.], v. 13, n. 7, p. 1061–1074, 2009.

MISHRA, V.; ELLENBURG, W. L.; GRIFFIN, R. E.; MECIKALSKI, J. R.; CRUISE, J. F.; HAIN, C. R.; ANDERSON, M. C. An initial assessment of a SMAP soil moisture disaggregation scheme using TIR surface evaporation data over the continental United States. **International Journal of Applied Earth Observation and Geoinformation**, [s. l.], v. 68, p. 92–104, 2018.

MMA. **ICMBIO - Centro Nacional de Pesquisa e Conservação da Biodiversidade do Cerrado e Caatinga - Biodiversidade**. [S. l.: s. n.], 2021. Disponível em: <https://www.icmbio.gov.br/cbc/conservacao-da-biodiversidade/biodiversidade.html>. Acesso em: 7 mar. 2022.

MOORE, C. J.; FISCH, G. Estimating heat storage in Amazonian tropical forest. **Agricultural and Forest Meteorology**, [s. l.], v. 38, n. 1, p. 147–168, 1986.

MORAES, T. J. de; MACHADO, N. G.; BIUDES, M. S.; BANGA, N. M.; CANEPPELE, L. B. Vegetation dynamics and precipitation sensitivity in three regions of northern Pantanal of Mato Grosso. **Brazilian Journal of Environmental Sciences (RBCIAMB)**, [s. l.], v. 57, n. 1, p. 125–136, 2022.

MORAN, M. S.; CLARKE, T. R.; INOUE, Y.; VIDAL, A. Estimating crop water deficit using the relation between surface-air temperature and spectral vegetation index. **Remote Sensing of Environment**, [s. l.], v. 49, n. 3, p. 246–263, 1994.

MUELLER, B.; SENEVIRATNE, S. I.; JIMENEZ, C.; CORTI, T.; HIRSCHI, M.; BALSAMO, G.; CIAIS, P.; DIRMEYER, P.; FISHER, J. B.; GUO, Z.; JUNG, M.; MAIGNAN, F.; MCCABE, M. F.; REICHLE, R.; REICHSTEIN, M.; RODELL, M.; SHEFFIELD, J.; TEULING, A. J.; WANG, K.; WOOD, E. F.; ZHANG, Y. Evaluation of global observations-based evapotranspiration datasets and IPCC AR4 simulations. **Geophysical Research Letters**, [s. l.], v. 38, n. 6, 2011. Disponível em:

<https://onlinelibrary.wiley.com/doi/abs/10.1029/2010GL046230>. Acesso em: 12 maio 2024.

MUÑOZ, S. J. ERA5-Land monthly averaged data from 1981 to present. **Copernicus Climate Change Service (C3S) Climate Data Store (CDS)**, [s. l.], 2019.

MUÑOZ-SABATER, J.; DUTRA, E.; AGUSTÍ-PANAREDA, A.; ALBERGEL, C.; ARDUINI, G.; BALSAMO, G.; BOUSSETTA, S.; CHOULGA, M.; HARRIGAN, S.; HERBACH, H.; MARTENS, B.; MIRALLES, D. G.; PILES, M.; RODRÍGUEZ-FERNÁNDEZ, N. J.; ZSOTER, E.; BUONTEMPO, C.; THÉPAUT, J.-N. ERA5-Land: a state-of-the-art global reanalysis dataset for land applications. **Earth System Science Data**, [s. l.], v. 13, n. 9, p. 4349–4383, 2021.

OLIOSO, A.; CHAUKI, H.; COURAULT, D.; WIGNERON, J.-P. Estimation of Evapotranspiration and Photosynthesis by Assimilation of Remote Sensing Data into SVAT Models. **Remote Sensing of Environment**, [s. l.], v. 68, n. 3, p. 341–356, 1999.

OLIVEIRA, R. S.; BEZERRA, L.; DAVIDSON, E. A.; PINTO, F.; KLINK, C. A.; NEPSTAD, D. C.; MOREIRA, A. Deep root function in soil water dynamics in cerrado savannas of central Brazil. **Functional Ecology**, [s. l.], v. 19, n. 4, p. 574–581, 2005.

OLSON, R.; FAN, Y.; EVANS, J. P. A simple method for Bayesian model averaging of regional climate model projections: Application to southeast Australian temperatures. **Geophysical Research Letters**, [s. l.], v. 43, n. 14, p. 7661–7669, 2016.

PABLOS, M.; GONZÁLEZ-ZAMORA, Á.; SÁNCHEZ, N.; MARTÍNEZ-FERNÁNDEZ, J. Assessment of Root Zone Soil Moisture Estimations from SMAP, SMOS and MODIS Observations. **Remote Sensing**, [s. l.], v. 10, n. 7, p. 981, 2018.

PAN, S.; DANGAL, S.; TAO, B.; YANG, J.; TIAN, H. Recent patterns of terrestrial net primary production in Africa influenced by multiple environmental changes. **Ecosystem Health and Sustainability**, [s. l.], v. 1, p. art18, 2015.

PAREDES, P.; MARTINS, D. S.; PEREIRA, L. S.; CADIMA, J.; PIRES, C. Accuracy of daily estimation of grass reference evapotranspiration using ERA-Interim reanalysis products with assessment of alternative bias correction schemes. **Agricultural Water Management**, [s. l.], v. 210, p. 340–353, 2018.

PARINUSSA, R. M.; HOLMES, T. R. H.; WANDERS, N.; DORIGO, W. A.; JEU, R. A. M. de. A Preliminary Study toward Consistent Soil Moisture from AMSR2. **Journal of Hydrometeorology**, [s. l.], v. 16, n. 2, p. 932–947, 2015.

PAVÃO, V. M. **Impacto da mudança de cobertura do solo na dinâmica da GPP, ET e WUE utilizando produtos derivados do sensor MODIS em Mato Grosso**. [S. l.: s. n.], 2021.

PEI, Y.; DONG, J.; ZHANG, Yao; YANG, J.; ZHANG, Yongqiang; JIANG, C.; XIAO, X. Performance of four state-of-the-art GPP products (VPM, MOD17, BESS

and PML) for grasslands in drought years. **Ecological Informatics**, [s. l.], v. 56, p. 101052, 2020.

PELOSI, A.; TERRIBILE, F.; D'URSO, G.; CHIRICO, G. B. Comparison of ERA5-Land and UERRA MESCAN-SURFEX Reanalysis Data with Spatially Interpolated Weather Observations for the Regional Assessment of Reference Evapotranspiration. **Water**, [s. l.], v. 12, n. 6, p. 1669, 2020.

PEREZ, P. J.; CASTELLVI, F.; IBÁÑEZ, M.; ROSELL, J. I. Assessment of reliability of Bowen ratio method for partitioning fluxes. **Agricultural and Forest Meteorology**, [s. l.], v. 97, n. 3, p. 141–150, 1999.

PEZZI, L. P.; QUADRO, M. F. L.; SOUZA, E. B.; MILLER, A. J.; RAO, V. B.; ROSA, E. B.; SANTINI, M. F.; BENDER, A.; SOUZA, R. B.; CABRERA, M. J.; PARISE, C. K.; CARVALHO, J. T.; LIMA, L. S.; DE QUADROS, M. R. L.; NEHME, D. M.; ANTÓNIO, J. F. Oceanic SACZ produces an abnormally wet 2021/2022 rainy season in South America. **Scientific Reports**, [s. l.], v. 13, n. 1, p. 1455, 2023.

PINHEIRO, J. R.; BIUDES, M. S.; MACHADO, N. G.; JUNIOR, A. L. P.; SANTOS, L. O. F. dos. Effect of urbanization on energy balance and evapotranspiration in an Amazon–Cerrado transition region in Brazil. **Journal of Applied Remote Sensing**, [s. l.], v. 16, n. 4, p. 044516, 2022.

POUSA, R.; COSTA, M. H.; PIMENTA, F. M.; FONTES, V. C.; BRITO, V. F. A. de; CASTRO, M. Climate Change and Intense Irrigation Growth in Western Bahia, Brazil: The Urgent Need for Hydroclimatic Monitoring. **Water**, [s. l.], v. 11, n. 5, p. 933, 2019.

PREIMESBERGER, W.; SCANLON, T.; SU, C.-H.; GRUBER, A.; DORIGO, W. Homogenization of Structural Breaks in the Global ESA CCI Soil Moisture Multisatellite Climate Data Record. **IEEE Transactions on Geoscience and Remote Sensing**, [s. l.], v. 59, n. 4, p. 2845–2862, 2021.

PRIANTE-FILHO, N.; VOURLITIS, G. L.; HAYASHI, M. M. S.; NOGUEIRA, J. D. S.; CAMPELO JR., J. H.; NUNES, P. C.; SOUZA, L. S. E.; COUTO, E. G.; HOEGER, W.; RAITER, F.; TRIENWEILER, J. L.; MIRANDA, E. J.; PRIANTE, P. C.; FRITZEN, C. L.; LACERDA, M.; PEREIRA, L. C.; BIUDES, M. S.; SULI, G. S.; SHIRAIWA, S.; PAULO, S. R. D.; SILVEIRA, M. Comparison of the mass and energy exchange of a pasture and a mature transitional tropical forest of the southern Amazon Basin during a seasonal transition. **Global Change Biology**, [s. l.], v. 10, n. 5, p. 863–876, 2004.

PRICE, J. C. On the analysis of thermal infrared imagery: The limited utility of apparent thermal inertia. **Remote Sensing of Environment**, [s. l.], v. 18, n. 1, p. 59–73, 1985.

PRIESTLEY, C. H. B.; TAYLOR, R. J. On the Assessment of Surface Heat Flux and Evaporation Using Large-Scale Parameters. **Monthly Weather Review**, [s. l.], v. 100, n. 2, p. 81–92, 1972.

QUERINO, C. A. S.; BIUDES, M. S.; MACHADO, N. G.; QUERINO, J. K. A. da S.; NETO, L. A. S.; SILVA, M. J. G. da; ARRUDA, P. H. Z. de; NOGUEIRA, J. de S. BALANÇO DE ONDAS CURTAS SOBRE FLORESTA SAZONALMENTE ALAGÁVEL DO PANTANAL MATO-GROSSENSE. **Revista Brasileira de Climatologia**, [s. l.], v. 20, n. 0, 2017. Disponível em: <https://revistas.ufpr.br/revistaabclima/article/view/50701>. Acesso em: 24 fev. 2022.

R. CORE TEAM. **A language and environment for statistical computing. R Foundation for Statistical Computing, Wien 2013**. [S. l.: s. n.], 2022. 2022.

RANJAN, A. K.; GORAI, A. K. Characterization of vegetation dynamics using MODIS satellite products over stone-mining dominated Rajmahal Hills in Jharkhand, India. **Remote Sensing Applications: Society and Environment**, [s. l.], v. 27, p. 100802, 2022.

RAWAT, K. S.; SEHGAL, V. K.; SINGH, S. K.; RAY, S. S. Soil moisture estimation using triangular method at higher resolution from MODIS products. **Physics and Chemistry of the Earth, Parts A/B/C**, [s. l.], v. 126, p. 103051, 2022.

REBOITA, M. S.; GAN, M. A.; ROCHA, R. P. da; AMBRIZZI, T. Regimes de precipitação na América do Sul: uma revisão bibliográfica. **Revista Brasileira de Meteorologia**, [s. l.], v. 25, p. 185–204, 2010.

REZENDE, L. F. C.; DE CASTRO, A. A.; VON RANDOW, C.; RUSCICA, R.; SAKSCHEWSKI, B.; PAPASTEFANOU, P.; VIOVY, N.; THONICKE, K.; SÖRENSSON, A.; RAMMIG, A.; CAVALCANTI, I. F. A. Impacts of Land Use Change and Atmospheric CO<sub>2</sub> on Gross Primary Productivity (GPP), Evaporation, and Climate in Southern Amazon. **Journal of Geophysical Research: Atmospheres**, [s. l.], v. 127, n. 8, p. e2021JD034608, 2022.

RODELL, M.; HOUSER, P. R.; JAMBOR, U.; GOTTSCHALCK, J.; MITCHELL, K.; MENG, C.-J.; ARSENAULT, K.; COSGROVE, B.; RADAKOVICH, J.; BOSILOVICH, M.; ENTIN, J. K.; WALKER, J. P.; LOHMANN, D.; TOLL, D. The Global Land Data Assimilation System. **Bulletin of the American Meteorological Society**, [s. l.], v. 85, n. 3, p. 381–394, 2004.

RODRIGUES, T. R.; DE PAULO, S. R.; NOVAIS, J. W. Z.; CURADO, L. F. A.; NOGUEIRA, J. S.; DE OLIVEIRA, R. G.; LOBO, F. de A.; VOURLITIS, G. L. Temporal Patterns of Energy Balance for a Brazilian Tropical Savanna under Contrasting Seasonal Conditions. **International Journal of Atmospheric Sciences**, [s. l.], v. 2013, p. e326010, 2013.

RODRIGUES, J. A. M.; VIOLA, M. R.; ALVARENGA, L. A.; DE MELLO, C. R.; CHOU, S. C.; DE OLIVEIRA, V. A.; UDDAMERI, V.; MORAIS, M. A. V. Climate change impacts under representative concentration pathway scenarios on streamflow and droughts of basins in the Brazilian Cerrado biome. **International Journal of Climatology**, [s. l.], v. 40, n. 5, p. 2511–2526, 2020.

ROERINK, G. J.; SU, Z.; MENENTI, M. S-SEBI: A simple remote sensing algorithm to estimate the surface energy balance. **Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere**, [s. l.], v. 25, n. 2, p. 147–157, 2000.

ROSSI, F. S.; SANTOS, G. A. de A. Fire dynamics in Mato Grosso State, Brazil: the relative roles of gross primary productivity. **Big Earth Data**, [s. l.], 2020. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/20964471.2019.1706832>. Acesso em: 29 jul. 2024.

ROUGIER, J. Comment on “Ensemble Averaging and the Curse of Dimensionality”. **Journal of Climate**, [s. l.], v. 31, n. 21, p. 9015–9016, 2018.

ROUGIER, J.; GOLDSTEIN, M.; HOUSE, L. Second-Order Exchangeability Analysis for Multimodel Ensembles. **Journal of the American Statistical Association**, [s. l.], v. 108, n. 503, p. 852–863, 2013.

RUI, H.; BEAUDOING, H.; LOESER, C. README document for NASA GLDAS version 2 data products. **Goddard Earth Sciences Data and Information Services Center (GES DISC): Greenbelt, MD, USA**, [s. l.], 2018.

RUNNING, S.; MU, Q.; ZHAO, M. Mod16a2 modis/terra net evapotranspiration 8-day l4 global 500m sin grid v006. **NASA EOSDIS Land Processes DAAC**, [s. l.], v. 6, 2017.

RUNNING, S.; MU, Q.; ZHAO, M. MYD17A2H MODIS/Aqua Gross Primary Productivity 8-Day L4 Global 500 m SIN Grid V006. **NASA EOSDIS Land Processes DAAC: Sioux Falls, SD, USA**, [s. l.], 2015.

SABINO, M.; SOUZA, A. P. de. **Global Sensitivity of Penman-Monteith Reference Evapotranspiration to Climatic Variables in Mato Grosso, Brazil**. Versão 2023080210. [S. l.]: Preprints, 2023. Disponível em: <https://www.preprints.org/manuscript/202308.0210/v1>. Acesso em: 28 ago. 2023.

SADEGHI, M.; BABAEIAN, E.; TULLER, M.; JONES, S. B. The optical trapezoid model: A novel approach to remote sensing of soil moisture applied to Sentinel-2 and Landsat-8 observations. **Remote Sensing of Environment**, [s. l.], v. 198, p. 52–68, 2017.

SALGADO, C. B.; JUNIOR, O. A. de C.; GOMES, R. A. T.; GUIMARÃES, R. F. Análise da interferência de nuvens na classificação de séries temporais MODIS-NDVI na região da Amazônia, município de Capixaba, Acre. **Sociedade & Natureza**, [s. l.], v. 31, 2019. Disponível em: <https://seer.ufu.br/index.php/sociedadnatureza/article/view/47062>. Acesso em: 24 out. 2024.

SANTOS, L. O. F. dos; MACHADO, N. G.; QUERINO, C. A. S.; JUNIOR, A. L. P.; IVO, I. O.; NETO, N. L.; BIUDES, M. S. HOURLY PRECIPITATION PATTERNS IN A BRAZILIAN TROPICAL CITY. **Revista Brasileira de Climatologia**, [s. l.], v.

26, n. 0, 2020. Disponível em: <https://revistas.ufpr.br/revistaabclima/article/view/71488>. Acesso em: 24 fev. 2022.

SANTOS, J. F. S. dos; NAVAL, L. P. Soy water footprint and socioeconomic development: An analysis in the new agricultural expansion areas of the Brazilian cerrado (Brazilian savanna). **Environmental Development**, [s. l.], p. 100670, 2021.

SCHMUGGE, T. J.; JACKSON, T. J.; MCKIM, H. L. Survey of methods for soil moisture determination. **Water Resources Research**, [s. l.], v. 16, n. 6, p. 961–979, 1980.

SEMENOV, M. A.; STRATONOVITCH, P. Use of multi-model ensembles from global climate models for assessment of climate change impacts. **Climate Research**, [s. l.], v. 41, n. 1, p. 1–14, 2010.

SENAY, G. B.; FRIEDRICH, M.; MORTON, C.; PARRISH, G. E. L.; SCHAUER, M.; KHAND, K.; KAGONE, S.; BOIKO, O.; HUNTINGTON, J. Mapping actual evapotranspiration using Landsat for the conterminous United States: Google Earth Engine implementation and assessment of the SSEBop model. **Remote Sensing of Environment**, [s. l.], v. 275, p. 113011, 2022.

SHARMA, D. N.; TARE, V. EVAPOTRANSPIRATION ESTIMATION USING SSEBop METHOD WITH SENTINEL -2 AND LANDSAT-8 DATA SET. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, [s. l.], v. XLII–5, p. 563–566, 2018.

SHI, Y.; REN, C.; YAN, Z.; LAI, J. High Spatial-Temporal Resolution Estimation of Ground-Based Global Navigation Satellite System Interferometric Reflectometry (GNSS-IR) Soil Moisture Using the Genetic Algorithm Back Propagation (GA-BP) Neural Network. **ISPRS International Journal of Geo-Information**, [s. l.], v. 10, n. 9, p. 623, 2021.

SONG, X.; LENG, P.; LI, Xiaotao; LI, Xinhui; MA, J. Retrieval of daily evolution of soil moisture from satellite-derived land surface temperature and net surface shortwave radiation. **International Journal of Remote Sensing**, [s. l.], v. 34, n. 9–10, p. 3289–3298, 2013.

SOUZA, M. C.; BIUDES, M. S.; DANELICHEN, V. H. de M.; MACHADO, N. G.; MUSIS, C. R. de; VOURLITIS, G. L.; NOGUEIRA, J. de S. Estimation of gross primary production of the Amazon-Cerrado transitional forest by remote sensing techniques. **Revista Brasileira de Meteorologia**, [s. l.], v. 29, p. 01–12, 2014.

SOUZA, C. M.; OLIVEIRA, L. A.; DE SOUZA FILHO, J. S.; FERREIRA, B. G.; FONSECA, A. V.; SIQUEIRA, J. V. Landsat sub-pixel land cover dynamics in the Brazilian Amazon. **Frontiers in Forests and Global Change**, [s. l.], v. 6, 2023. Disponível em: <https://www.frontiersin.org/journals/forests-and-global-change/articles/10.3389/ffgc.2023.1294552/full>. Acesso em: 26 out. 2024.

SOUZA, C. M.; Z. SHIMBO, J.; ROSA, M. R.; PARENTE, L. L.; A. ALENCAR, A.; RUDORFF, B. F. T.; HASENACK, H.; MATSUMOTO, M.; G. FERREIRA, L.; SOUZA-FILHO, P. W. M.; DE OLIVEIRA, S. W.; ROCHA, W. F.; FONSECA, A. V.; MARQUES, C. B.; DINIZ, C. G.; COSTA, D.; MONTEIRO, D.; ROSA, E. R.; VÉLEZ-MARTIN, E.; WEBER, E. J.; LENTI, F. E. B.; PATERNOST, F. F.; PAREYN, F. G. C.; SIQUEIRA, J. V.; VIERA, J. L.; NETO, L. C. F.; SARAIVA, M. M.; SALES, M. H.; SALGADO, M. P. G.; VASCONCELOS, R.; GALANO, S.; MESQUITA, V. V.; AZEVEDO, T. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sensing**, [s. l.], v. 12, n. 17, p. 2735, 2020.

SPATAFORA, L. R.; VALL-LLOSSERA, M.; CAMPS, A.; CHAPARRO, D.; ALVALÁ, R. C. dos S.; BARBOSA, H. Validation of SMOS L3 AND L4 Soil Moisture Products In The Remedhus (SPAIN) AND CEMADEN (BRAZIL) Networks. **Revista Brasileira de Geografia Física**, [s. l.], v. 13, n. 2, p. 691–712, 2020.

SPENNEMANN, P. C.; RIVERA, J. A.; SAULO, A. C.; PENALBA, O. C. A Comparison of GLDAS Soil Moisture Anomalies against Standardized Precipitation Index and Multisatellite Estimations over South America. **Journal of Hydrometeorology**, [s. l.], v. 16, n. 1, p. 158–171, 2015.

SURCEL, M.; ZAWADZKI, I.; YAU, M. K. On the Filtering Properties of Ensemble Averaging for Storm-Scale Precipitation Forecasts. **Monthly Weather Review**, [s. l.], v. 142, n. 3, p. 1093–1105, 2014.

TEBALDI, C.; KNUTTI, R. The use of the multi-model ensemble in probabilistic climate projections. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, [s. l.], v. 365, n. 1857, p. 2053–2075, 2007.

ULIANA, E. M.; AIRES, U. R. V.; SOUSA JUNIOR, M. F. de; SILVA, D. D. da; MOREIRA, M. C.; CRUZ, I. F. da; ARAUJO, H. B. Estimated evaporation of lakes by climate reanalysis data and artificial neural networks. **Journal of South American Earth Sciences**, [s. l.], v. 136, p. 104811, 2024.

VÁSQUEZ P., I. L.; ALVES BARBOSA, H.; SAMPAIO, G.; SÁNCHEZ P., C. A.; UTIDA, G.; PAREJA QUISPE, D.; REJAS AYUGA, J. G.; ABI KARAM, H.; MAKSIC, J.; SHIMIZU, M. H.; WILLIAM CRUZ, F. Multidecadal variability of the ITCZ from the Last Millennium Extreme Precipitation Changes in Northeastern Brazil. **EGUsphere**, [s. l.], p. 1–26, 2022.

VOURLITIS, G. L.; DE ALMEIDA LOBO, F.; BIUDES, M. S.; RODRÍGUEZ ORTÍZ, C. E.; DE SOUZA NOGUEIRA, J. Spatial Variations in Soil Chemistry and Organic Matter Content across a *Vochysia divergens* Invasion Front in the Brazilian Pantanal. **Soil Science Society of America Journal**, [s. l.], v. 75, n. 4, p. 1554–1561, 2011.

VOURLITIS, G. L.; DE ALMEIDA LOBO, F.; LAWRENCE, S.; CODOLO DE LUCENA, I.; PINTO JR., O. B.; DALMAGRO, H. J.; CARMEN, E.; RODRIGUEZ, O.; DE SOUZA NOGUEIRA, J. Variations in Stand Structure and Diversity along a Soil Fertility Gradient in a Brazilian Savanna (Cerrado) in Southern Mato Grosso. **Soil Science Society of America Journal**, [s. l.], v. 77, n. 4, p. 1370–1379, 2013.

WAGNER, W.; HAHN, S.; KIDD, R.; MELZER, T.; BARTALIS, Z.; HASENAUER, S.; FIGA-SALDAÑA, J.; DE ROSNAY, P.; JANN, A.; SCHNEIDER, S.; KOMMA, J.; KUBU, G.; BRUGGER, K.; AUBRECHT, C.; ZÜGER, J.; GANGKOFNER, U.; KIENBERGER, S.; BROCCA, L.; WANG, Y.; BLÖSCHL, G.; EITZINGER, J.; STEINNOCHER, K. The ASCAT Soil Moisture Product: A Review of its Specifications, Validation Results, and Emerging Applications. **Meteorologische Zeitschrift**, [s. l.], p. 5–33, 2013.

WANG, Z.; TIAN, H.; YANG, J.; SHI, H.; PAN, S.; YAO, Y.; BANGER, K.; YANG, Q. Coupling of Phosphorus Processes With Carbon and Nitrogen Cycles in the Dynamic Land Ecosystem Model: Model Structure, Parameterization, and Evaluation in Tropical Forests. **Journal of Advances in Modeling Earth Systems**, [s. l.], v. 12, n. 10, p. e2020MS002123, 2020.

WANG, L.; ZHU, H.; LIN, A.; ZOU, L.; QIN, W.; DU, Q. Evaluation of the Latest MODIS GPP Products across Multiple Biomes Using Global Eddy Covariance Flux Data. **Remote Sensing**, [s. l.], v. 9, n. 5, p. 418, 2017.

WATERS, R.; ALLEN, R.; BASTIAANSEN, W.; TASUMI, M.; TREZZA, R. Sebal. **Surface energy balance algorithms for land. Idaho implementation. Advanced Training and Users Manual, Idaho, USA**, [s. l.], 2002.

WILLMOTT, C. J.; ACKLESON, S. G.; DAVIS, R. E.; FEDDEMA, J. J.; KLINK, K. M.; LEGATES, D. R.; O'DONNELL, J.; ROWE, C. M. Statistics for the evaluation and comparison of models. **Journal of Geophysical Research: Oceans**, [s. l.], v. 90, n. C5, p. 8995–9005, 1985.

WU, Q.; LIU, H.; WANG, L.; DENG, C. Evaluation of AMSR2 soil moisture products over the contiguous United States using in situ data from the International Soil Moisture Network. **International Journal of Applied Earth Observation and Geoinformation**, [s. l.], v. 45, Advances in the Validation and Application of Remotely Sensed Soil Moisture - Part 1, p. 187–199, 2016.

XIA, Y.; SHEFFIELD, J.; EK, M. B.; DONG, J.; CHANEY, N.; WEI, H.; MENG, J.; WOOD, E. F. Evaluation of multi-model simulated soil moisture in NLDAS-2. **Journal of Hydrology**, [s. l.], v. 512, p. 107–125, 2014.

XIAO, C.; YE, J.; ESTEVES, R. M.; RONG, C. Using Spearman's correlation coefficients for exploratory data analysis on big dataset. **Concurrency and Computation: Practice and Experience**, [s. l.], v. 28, n. 14, p. 3866–3878, 2016.

XU, X.; FREY, S. K. Validation of SMOS, SMAP, and ESA CCI Soil Moisture Over a Humid Region. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [s. l.], v. 14, p. 10784–10793, 2021.

XU, C.; WANG, W.; HU, Y.; LIU, Y. Evaluation of ERA5, ERA5-Land, GLDAS-2.1, and GLEAM potential evapotranspiration data over mainland China. **Journal of Hydrology: Regional Studies**, [s. l.], v. 51, p. 101651, 2024.

YADAV, S. K.; SINGH, P.; JADAUN, S. P. S.; KUMAR, N.; UPADHYAY, R. K. SOIL MOISTURE ANALYSIS OF LALITPUR DISTRICT UTTAR PRADESH INDIA USING LANDSAT AND SENTINEL DATA. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, [s. l.], v. XLII-3/W6, p. 351–356, 2019.

YANG, Y.; GUAN, H.; LONG, D.; LIU, B.; QIN, G.; QIN, J.; BATELAAN, O. Estimation of Surface Soil Moisture from Thermal Infrared Remote Sensing Using an Improved Trapezoid Method. **Remote Sensing**, [s. l.], v. 7, n. 7, p. 8250–8270, 2015.

YANG, Z.; HUANG, Y.; DUAN, Z.; TANG, J. Capturing the spatiotemporal variations in the gross primary productivity in coastal wetlands by integrating eddy covariance, Landsat, and MODIS satellite data: A case study in the Yangtze Estuary, China. **Ecological Indicators**, [s. l.], v. 149, p. 110154, 2023.

YANG, F.; LU, H.; YANG, K.; HE, J.; WANG, W.; WRIGHT, J. S.; LI, C.; HAN, M.; LI, Y. Evaluation of multiple forcing data sets for precipitation and shortwave radiation over major land areas of China. **Hydrology and Earth System Sciences**, [s. l.], v. 21, n. 11, p. 5805–5821, 2017.

YANG, Y.; SUN, H.; XUE, J.; LIU, Y.; LIU, L.; YAN, D.; GUI, D. Estimating evapotranspiration by coupling Bayesian model averaging methods with machine learning algorithms. **Environmental Monitoring and Assessment**, [s. l.], v. 193, n. 3, p. 156, 2021.

YIN, L.; WANG, X.; FENG, X.; FU, B.; CHEN, Y. A Comparison of SSEBop-Model-Based Evapotranspiration with Eight Evapotranspiration Products in the Yellow River Basin, China. **Remote Sensing**, [s. l.], v. 12, n. 16, p. 2528, 2020.

ZENG, J.; PENG, J.; ZHAO, W.; MA, C.; MA, H. Microwave Remote Sensing of Soil Moisture. **Remote Sensing**, [s. l.], v. 15, n. 17, p. 4243, 2023.

ZHANG, Y.; HU, Z.; WANG, J.; GAO, X.; YANG, C.; YANG, F.; WU, G. Temporal upscaling of MODIS instantaneous FAPAR improves forest gross primary productivity (GPP) simulation. **International Journal of Applied Earth Observation and Geoinformation**, [s. l.], v. 121, p. 103360, 2023.

ZHANG, Y.; KONG, D.; GAN, R.; CHIEW, F. H. S.; MCVICAR, T. R.; ZHANG, Q.; YANG, Y. Coupled estimation of 500 m and 8-day resolution global evapotranspiration and gross primary production in 2002–2017. **Remote Sensing of Environment**, [s. l.], v. 222, p. 165–182, 2019.

ZHANG, Y.; PEÑA-ARANCIBIA, J. L.; MCVICAR, T. R.; CHIEW, F. H. S.; VAZE, J.; LIU, C.; LU, X.; ZHENG, H.; WANG, Y.; LIU, Y. Y.; MIRALLES, D. G.; PAN, M. Multi-decadal trends in global terrestrial evapotranspiration and its components. **Scientific Reports**, [s. l.], v. 6, n. 1, p. 19124, 2016.

ZHANG, G.; SU, X.; AYANTOBO, O. O.; FENG, K. Drought monitoring and evaluation using ESA CCI and GLDAS-Noah soil moisture datasets across China. **Theoretical and Applied Climatology**, [s. l.], v. 144, n. 3, p. 1407–1418, 2021.

ZHANG, Y.; TAN, K.; WANG, X.; CHEN, Y. Retrieval of Soil Moisture Content Based on a Modified Hapke Photometric Model: A Novel Method Applied to Laboratory Hyperspectral and Sentinel-2 MSI Data. **Remote Sensing**, [s. l.], v. 12, n. 14, p. 2239, 2020.

ZHANG, D.; ZHOU, G. Estimation of Soil Moisture from Optical and Thermal Remote Sensing: A Review. **Sensors**, [s. l.], v. 16, n. 8, p. 1308, 2016.

ZHOU, J.; DEITCH, M. J.; GRUNWALD, S.; SCREATON, E. Do the Mann-Kendall test and Theil-Sen slope fail to inform trend significance and magnitude in hydrology?. **Hydrological Sciences Journal**, [s. l.], v. 68, n. 9, p. 1241–1249, 2023.

ZHOU, S.; YU, B.; SCHWALM, C. R.; CIAIS, P.; ZHANG, Y.; FISHER, J. B.; MICHALAK, A. M.; WANG, W.; POULTER, B.; HUNTZINGER, D. N.; NIU, S.; MAO, J.; JAIN, A.; RICCIUTO, D. M.; SHI, X.; ITO, A.; WEI, Y.; HUANG, Y.; WANG, G. Response of Water Use Efficiency to Global Environmental Change Based on Output From Terrestrial Biosphere Models. **Global Biogeochemical Cycles**, [s. l.], v. 31, n. 11, p. 1639–1655, 2017.